

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
імені ІГОРЯ СІКОРСЬКОГО»**

Факультет прикладної математики

Кафедра програмного забезпечення комп'ютерних систем

«На правах рукопису»
УДК 004.89

«До захисту допущено»

Науковий керівник кафедри

_____ І.А. Дичка

«___» _____ 2019 р.

Магістерська дисертація

на здобуття ступеня магістра

зі спеціальності 121 Інженерія програмного забезпечення

**на тему: «Спосіб та програмне забезпечення для класифікації
медичних зображень за допомогою згорткових нейронних мереж»**

Виконав:

студент II курсу, групи КП-81мп

Целікін Вадим Віталійович _____

Керівник:

Доцент кафедри ПЗКС, к.т.н., доцент

Сулема Євгенія Станіславівна _____

Консультант з нормоконтролю:

Доцент кафедри ПЗКС, к.т.н., доцент

Онай Микола Володимирович _____

Рецензент:

В.о. завідувач кафедри ММСА

Інститут прикладного системного

аналізу, доцент, к.т.н.

Тимошук Оксана Леонідівна _____

Засвідчую, що у цій магістерській
дисертації немає запозичень з праць
інших авторів без відповідних
посилань.

Студент _____

Київ – 2019 року

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Факультет прикладної математики

Кафедра програмного забезпечення комп'ютерних систем

Рівень вищої освіти – другий (магістерський) за освітньо-професійною програмою
Спеціальність (освітня програма) – 121 «Інженерія програмного забезпечення»
(«Інженерія програмного забезпечення комп'ютерних та інформаційно пошукових систем»)

ЗАТВЕРДЖУЮ

Науковий керівник кафедри

_____ І.А. Дичка

«__» _____ 2018 р.

ЗАВДАННЯ
на магістерську дисертацію студенту

Целікіну Вадиму Віталійовичу

1. Тема дисертації «Спосіб та програмне забезпечення для класифікації медичних зображень за допомогою згорткових нейронних мереж», науковий керівник дисертації Сулема Євгенія Станіславівна, к.т.н., доцент, затверджені наказом по університету від «13» листопада 2019 р. № 3895-С
2. Термін подання студентом дисертації «16» грудня 2019 р.
3. Об'єкт дослідження: процеси обробки аналіз виявлення особливостей на медичних зображень.
4. Предмет дослідження: методи класифікації медичних зображень та впровадження згорткових нейронних мереж.
5. Перелік завдань, які потрібно розробити:
 - провести аналіз методів глибокого навчання для класифікації медичних зображень;
 - дослідити способи обробки медичних зображень;
 - впровадити згорткову нейронну мережу для даної проблеми;
 - навчити згорткову нейронну мережу класифікувати медичні зображення для виявлення особливостей захворювання;
 - обґрунтувати вибір критеріїв оптимізації та налаштування мережі;
 - провести експерименти з метою визначення найбільш точної оцінки класифікацій зображень;
6. Орієнтовний перелік графічного (ілюстративного) матеріалу:
 - візуалізація медичних зображень;
 - архітектура штучних нейронних мереж;
 - архітектура методу опорних векторів;

- архітектура згорткових нейронних мереж;
- таблиці оцінки типів сегментації;
- таблиця отриманих результатів;

7. Орієнтовний перелік публікацій:

- Тези доповіді “Попередня класифікація медичних зображень”

8. Консультанти розділів дисертації

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Нормоконтроль	Онай М.В., к.т.н., доцент		

9. Дата видачі завдання «04» жовтня 2018 р.

Календарний план

№ з/п	Назва етапів виконання магістерської дисертації	Термін виконання етапів магістерської дисертації	Примітка
1.	Грунтовне ознайомлення з предметною галуззю	17.10.2018	
2.	Визначення структури магістерської дисертації; вивчення літератури, пошук додаткової літератури, патентний пошук	04.12.2018	
3.	Робота над першим розділом магістерської дисертації; проведення наукового дослідження	15.02.2019	
4.	Проведення наукового дослідження; робота над другим розділом магістерської дисертації; розроблення програмного забезпечення	05.04.2019	
5.	Проведення наукового дослідження; робота над статтею за результатами наукового дослідження	15.05.2019	
6.	Проведення наукового дослідження; робота над третім розділом магістерської дисертації	15.06.2019	
7.	Завершення роботи над основною частиною магістерської дисертації; підготовка ілюстративного матеріалу; підготовка матеріалів доповіді на конференції ПМК-2018	05.11.2019	
8.	Оформлення текстової і графічної частини магістерської дисертації	04.12.2019	

Студент

В.В. Целікін

Науковий керівник дисертації

Є.С. Сулема

РЕФЕРАТ

Актуальність теми. Магістерська дисертація присвячена розробці програмного забезпечення для автоматизованого виявлення хвороби Альцгеймера на ранніх стадіях з високою точністю. Захворювання Альцгеймера – найпоширеніша у світі форма деменції, яка набирає оберти з кожним роком. Захворювання фінансово затратне і недостатньо досліджене у наші часи. Раннє виявлення має вирішальне значення, оскільки лікарські засоби, що полегшують симптоми деменції та є найбільш ефективними, якщо їх починають приймати на початку хвороби, до виникнення незворотніх пошкоджень мозку, тому існує велика зацікавленість у розробці нових методів для раннього виявлення хвороби. Порушення головного мозку є чутливою ознакою захворювання, які спостерігаються на МРТ – зображеннях та є біологічними маркерами захворювання. Технології машинного навчання, а особливо технології глибокого машинного навчання, можуть вивчити особливості з об'ємних даних, і тим самим забезпечити автоматичну діагностику хвороби Альцгеймера.

Об'єктом дослідження є процес обробки та аналіз у виявленні особливостей на медичних зображеннях.

Предметом дослідження є методи класифікації медичних зображень та впровадження згорткових нейронних мереж.

Мета роботи присвячена розробленню програмного забезпечення для автоматизованого виявлення хвороби Альцгеймера на ранніх стадіях шляхом аналізу МРТ-зображень мозку пацієнтів за допомогою згорткових нейронних мереж тому, що **класифікації медичних зображень** залишається відкритою та великою проблемою у медичних експертних знаннях.

Методи дослідження: в роботі використовуються методи теоретичного дослідження: аналіз існуючих методів класифікації медичних зображень, застосування методів глибокого навчання для попереднього

виявлення хвороби Альцгеймера. Також застосовувалися емпіричні методи: порівняння та проведення експериментів з метою визначення найбільш точної оцінки зображень мозку для діагностики хвороби Альцгеймера на ранніх стадіях.

Наукова новизна роботи полягає у додатковій обробці зображень згідно запропонованому способу та за допомогою згорткових нейронних мереж автоматизовано виявляти хворобу Альцгеймера на ранніх стадіях, запропонований спосіб додав до точності виявлення близько 10%.

Практична цінність отриманих результатів роботи полягає в тому, що додаткова обробка зображень та застосування згорткових нейронних мереж дають змогу підвищити точність виявлення хвороби Альцгеймера на ранніх стадіях. Також в рамках даного дослідження було розроблене програмне забезпечення, яке дає можливість виявляти хворобу по МРТ-зображенням.

Апробація роботи. Основні положення і результати роботи були представлені та обговорювались на XII науковій конференції магістрантів та аспірантів «Прикладна математика та комп'ютинг» ПМК – 2019 та опубліковані у збірнику тез доповідей.

За результатами роботи була написана наукова стаття на тему «Попередня класифікація медичних зображень за допомогою згорткових нейронних мереж».

Структура та обсяг роботи. Магістерська дисертація складається з вступу, п'яти розділів, висновків та додатків.

У вступі надано загальну характеристику роботи, виконано оцінку сучасного стану проблеми, обґрунтовано актуальність напрямку досліджень, сформульовано мету і задачі досліджень.

У першому розділі описана теорія класифікації зображень та розглянуто основи досліджень хвороби Альцгеймера. Була представлена

відповідна інформація щодо деменції, технології магнітно – резонансної томографії та отриманих зображень.

У другому розділі розглянуті відповідні галузі машинного навчання та сучасні підходи, такі як глибоке навчання та пов'язані інші методи, що застосовувалися в минулих дослідженнях виявлення хвороби Альцгеймера. Було розглянуто принцип роботи згорткових нейронних мереж, проаналізовані переваги та недоліки.

У третьому розділі запропонований спосіб обробки медичних зображень для покращення точності; сформовані основні вимоги до автоматизованої системи виявлення хвороби по структурним МРТ-зображенням; описано набір даних для навчання мережі; описані способи зменшення розмірності зображень; описані методи сегментації зображень для полегшення класифікації; обґрунтовано вибір засобів, що використовувались при розробці.

У четвертому розділі визначено критерії оцінки ефективності, які застосовуються до нейронної мережі; проведено порівняльний аналіз ефективності отриманих результатів та минулих досліджень.

У п'ятому розділі було проведено аналіз поточної ситуації у сфері визначення хвороби Альцгеймера, виявлено наявні проблеми та підсумовано їх у відповідному дереві проблем. Було проведено аналіз майбутніх клієнтів, досліджено сегменти ринку споживання. Це дозволило спрогнозувати потенційні доходи та витрати на реалізацію продукту.

У висновках проаналізовано отримані результати роботи.

Робота виконана на 100 аркушах, містить додатки та посилання на список використаних літературних джерел з 18 найменувань. У роботі наведено 10 рисунків та 5 таблиць.

Ключові слова: автоматизована система виявлення хвороби, класифікація зображень, хвороба Альцгеймера, згорткові нейронні мережі, метод опорних векторів, набір даних медичних зображень.

ABSTRACT

Actuality. The master's thesis is dedicated to the development of software for the automated detection of Alzheimer's disease in the early stages with high accuracy. Alzheimer's disease is the most common form of dementia in the world, which is gaining momentum every year. The disease is costly and under-researched in our time. Early detection is crucial because drugs that alleviate dementia symptoms are most effective when introduced at the onset of the disease before irreversible brain damage occurs, so there is a great deal of interest in developing new early detection methods. Structural disorders of the brain are a sensitive sign of the disease, which are observed on the dead images and are biological markers of the disease. Machine learning technologies, and in particular deep machine learning technologies, can study the features of volumetric data such as structural MRI images, and thus provide an automatic diagnosis of Alzheimer's disease.

The object of research is the process of analyzing medical images and diagnosing the disease, in this case, Alzheimer's disease.

Subjects of research are methods and algorithms for processing existing medical images and analysis of neural networks.

Goal of the work is to develop software for automated early detection of Alzheimer's disease with high precision using convolutional neural networks and structural magnetic resonance imaging of the subjects' brains.

Methods of research is to develop software for the automated detection of Alzheimer's disease in the early stages by analyzing MRI images of patients' brains using convolutional neural networks, because the classification of medical images remains an open and big problem in medical expertise.

The scientific novelty of the work is the additional processing of images according to the proposed method and using convolutional neural networks to automatically detect Alzheimer's disease in the early stages, the proposed method added to an accuracy of detection of about 10%.

The practical value of the results obtained is that additional image processing and the use of convolutional neural networks allow to increase the accuracy of early detection of Alzheimer's disease. Also, in the framework of this study, software was developed that enables detection of MRI images.

Approbation. The main provisions and results of the work were presented and discussed at the XII scientific conference of masters and postgraduates "Applied Mathematics and Computer" PMK-2019 and published in the proceedings.

As a result of the work, a scientific article on the topic "Medical Image Pre-Classification Using Convolutional Neural Network".

Structure and content of the thesis. Master's thesis consists of an introduction, five chapters, conclusions, and appendices.

The introduction provides general characteristics of the work are given, the current state of the problem is assessed, the relevance of the research direction is substantiated, the purpose and tasks of the research are formulated.

The first chapter describes the task of selecting team members to implement software development projects, features of automated decision support systems were considered, the existing methods of intelligent data analysis for solving the problem were examined.

The second chapter discusses the relevant areas of machine learning and current approaches such as deep learning and related other techniques used in past Alzheimer's disease research have been considered. The principle of convolutional neural networks was considered, advantages and disadvantages were analyzed.

The third chapter proposes a method for processing medical images to improve accuracy; the basic requirements to the automated system of detection of the disease on structural MRI images are formed; describes a dataset for training the network; described ways to reduce the image size; methods of image segmentation are described to facilitate classification; the choice of the means used in the development is justified.

The fourth chapter defines performance evaluation criteria applied to the neural network; a comparative analysis of the effectiveness of the results obtained and past studies.

In the fifth section, an analysis of the current situation in the field of Alzheimer's disease is identified, identified problems and summarized in the appropriate tree of problems. The analysis of future customers was conducted, the segments of the consumption market were investigated. This made it possible to predict the potential revenue and costs of the product.

The conclusion contains a brief overview of the results obtained in the work.

The work is done on 100 pages, contains appendices and a reference list of 18 titles. The work contains 10 pictures and 5 tables.

Keywords: automated disease detection system, image classification, Alzheimer's disease, convolutional neural networks, support vector machines, data set of structural MRI – brain images.

3MICT

СПИСОК ТЕРМІНІВ ТА СКОРОЧЕНЬ.....	11
ВСТУП.....	13
1. КЛАСИФІКАЦІЯ ЗОБРАЖЕНЬ МЕТОДАМИ МАШИННОГО НАВЧАННЯ ТА ПОНЯТТЯ ХВОРОБИ АЛЬЦГЕЙМЕРА.....	15
1.1. Машинне навчання та класифікація зображень.....	15
1.2. Поняття хвороби Альцгеймера.....	18
1.3. Магнітно-резонансна томографія.....	21
1.4. Висновки.....	22
2. СПОСОБИ МАШИННОГО НАВЧАННЯ ТА ЗГОРТКОВА НЕЙРОННА МЕРЕЖА.....	23
2.1. Способи машинного навчання.....	23
2.2. Основні етапи навчання нейронної мережі.....	29
2.3. Показники нейронної мережі.....	38
2.4. Висновки.....	42
3. СПОСІБ ПОКРАЩЕННЯ ТОЧНОСТІ КЛАСИФІКАЦІЇ ТА РОЗРОБЛЕННЯ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ.....	43
3.1. Алгоритм роботи програми.....	43
3.2. Минулі запропоновані алгоритми.....	44
3.3. Основні етапи для покращення класифікації зображень.....	46
3.4. Висновки.....	53
4. ПРОВЕДЕННЯ ЕКСПЕРИМЕНТІВ ТА ПОРІВНЯННЯ ОТРИМАНИХ РЕЗУЛЬТАТІВ.....	51
4.1. Проведення експериментів.....	55
4.2. Сегментація зображень.....	56
4.3. Аналіз отриманих результатів.....	58
4.4. Висновки.....	59
5. СТАРТАП.....	60
5.1. Опис проблеми.....	60
5.2. Зацікавлені сторони.....	61
5.3. Комерційне рішення.....	65
5.4. Конкурентні переваги рішення.....	65
5.5. Сегмент ринку споживання.....	66
5.6. Доходи та витрати.....	69
5.7. Унікальна ціннісна пропозиція.....	71
5.8. Бізнес модель.....	72
5.9. Висновки.....	75
ВИСНОВКИ.....	76

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	78
ДОДАТКИ.....	80

СПИСОК ТЕРМІНІВ ТА СКОРОЧЕНЬ

Ініціативна група нейровізуалізації хвороби Альцгеймера (ADNI) – всесвітній проект, що надає дослідникам достовірні клінічні дані про хворобу Альцгеймера.

Штучні нейронні мережі (ANN) – це моделі, що забезпечують надійні загальні методи глибинного навчання.

Метод опорних векторів (SVM) – машинний алгоритм, котрий навчається на прикладах та використовується для класифікації об'єктів.

Згорткова нейронна мережа (ConvNet/CNN) – клас глибоких штучних нейронних мереж прямого поширення, який успішно застосовувався для аналізу візуальних зображень.

Легка когнітивна недостатність (ЛКН) – хвороба Альцгеймера на ранній стадії. У пацієнтів з ЛКН зміни головного мозку вже тривають досить давно, і симптоми тільки починають з'являтися.

Магнітно-резонансна томографія (МРТ) – томографічний метод дослідження внутрішніх органів і тканин з використанням фізичного явища ядерного магнітного резонансу.

Алгоритм зворотного поширення (Backpropagation) – метод глибокого навчання для штучних нейронних мереж, який є узагальненням правила дельти до багатошарової прямої мережі.

Аналіз основних компонентів (РСА) – один з основних способів зменшити розмірність даних, втративши найменшу кількість інформації.

ВСТУП

Машинне навчання – це підгалузь штучного інтелекту в галузі інформатики: мультидисциплінарна сфера, що спирається на дослідження з різних наукових галузей, таких як статистика, штучний інтелект, нейробіологія та філософія. У своїй книзі «Машинне навчання» [1] Том Мітчелл визначив сферу машинного навчання як один із розділів штучного інтелекту, що дозволяють дозволяють комп'ютеру робити висновки на підставі даних, не слідуючи жорстко заданим правилами. Класифікації за допомогою нейронних мереж активно застосовуються в медицині: можна

навчити нейронну мережу класифікації хвороб або симптомів, наприклад, за допомогою МРТ-діагностики.

Хвороба Альцгеймера – це нейродегенеративне захворювання та найпоширеніший тип деменції у всьому світі. Поточна поширеність становить близько 2% у віці 65 та 35% у віці 85 років. Зі збільшенням тривалості життя кількість людей, які страждають на захворювання, швидко зростає. Діагностувати хворобу Альцгеймера часто важко, особливо на ранніх стадіях. Діагностика хвороби традиційно покладалася головним чином на клінічне спостереження та когнітивну оцінку. Причому, в основному точність діагностування залежить від досвіду рентгенологів. Протягом останніх років було проведено багато досліджень щодо автоматизації діагностики хвороби. В нещодавніх дослідженнях почали використовувати методи вилучення ознак та методи класифікації зображень за допомогою нейронних мереж. Дослідження, вказують на те, що аналіз зображень при скануванні нейровізуальних зображень може бути більш надійним і чутливим підходом.

Сьогодні, більше уваги приділяється пошуку біомаркерів та застосуванню методів машинного навчання для автоматизованої діагностики хвороби Альцгеймера. Багато провідних дослідницьких проектів у світі значно сприяють подальшому розумінню захворювання шляхом надання достовірних клінічних даних для дослідницьких цілей, включаючи маркований набір даних пацієнтів з різними діагностичними групами, що складаються з зображень магнітно томографічного резонансу. Штучні нейронні мережі успішно застосовуються до клінічних систем підтримки прийняття рішень, а також діагностичної допомоги в галузі медицини, а саме радіології, кардіології, онкології та ін. з метою розробки більш економічних і простих у використанні систем підтримки клініцистів. Цей тип комп'ютерної діагностики особливо цікавий в контексті ранньої діагностики, що є дуже важливим у випадку хвороби Альцгеймера.

В цілому існує багато способів вирішення описаної проблеми, але всі вони не досконалі, тому пошук нових підходів до обробки та класифікації медичних зображень мозку та автоматизованої діагностики хвороби Альцгеймера є актуальною задачею.

Дослідження присвячене вирішенню таких задач: аналіз існуючих методів класифікації медичних зображень; використання різних способів обробки медичних зображень для полегшення класифікації; застосування методів глибинного навчання для попереднього виявлення хвороби Альцгеймера; проведення експериментів з метою визначення найбільш точної оцінки зображень мозку для діагностики хвороби Альцгеймера на ранніх стадіях.

1. КЛАСИФІКАЦІЯ ЗОБРАЖЕНЬ МЕТОДАМИ МАШИННОГО НАВЧАННЯ ТА ПОНЯТТЯ ХВОРОБИ АЛЬЦГЕЙМЕРА

1.1. Машинне навчання та класифікація зображень

Машинне навчання є головною складовою теорії штучного інтелекту, глибокою математичною дисципліною, до якої відносяться науки математична статистика та теорія ймовірностей. Зазначимо два типи машинного навчання, що активно використовуються: індуктивне навчання та дедуктивне навчання. Індуктивне навчання базується на обробці

емпіричних даних, а дедуктивне – на формалізації отриманих знань та подальшого їх упорядкування. Мітчелл [3] визначає індуктивну гіпотезу навчання як "будь-яку гіпотезу, яка виявила апроксимацію цільової функції над досить великим набором навчальних прикладів, що також буде наближати цільову функцію до інших непомічених прикладів". Прийнято вважати, що область експертних систем включає дедуктивне навчання, тому і використовується в теорії і практиці машинного навчання загалом. Розділ машинного навчання виник у результаті поділу науки про нейронні мережі в рамках науки про штучний інтелект на методи навчання мереж і види топологій архітектури мереж, увібравши в себе деякі інші області, такі як методи математичної статистики і теорію дискретного аналізу.

Машинне навчання використовує ті ж самі методи, що й інтелектуальний аналіз даних (з якого машинне навчання забезпечує технічну базу) в умовах навчання без вчителя, або в кроках попередньої обробки.

Система машинного навчання складається, як правило, з трьох частин: дані про навчання, модель та алгоритм навчання. Навчання можна пояснити як пристосування параметрів моделі до наданих навчальних даних. Мета навчального процесу полягає в тому, щоб система змогла узагальнити свій досвід з навчальними даними, добре працюючи на раніше небачених екземплярах даних. Машинне навчання можна орієнтовно розділити на дві парадигми навчання, а саме: з вчителем, без вчителя. Навчання з вчителем стосується мічених прикладних даних, де вхідні дані поєднуються з бажаними вихідними значеннями. Це можна розглядати як паралель психологічної концепції поняття навчання. З іншого боку, при навчанні без вчителя, приклади навчання не є міченими (тобто не відомі вихідні дані). Система спонтанно навчається виконувати поставлене завдання, без втручання з боку експериментатора.

Це призводить до того, що не існує жодних помилок або сигналу винагороди, за допомогою яких можна оцінити потенційне рішення.

Алгоритм навчання намагається мінімізувати деяку міру помилок (тобто функцію втрат), наприклад середню квадратичну помилку або найменші середні квадрати. Намагаючись вибрати ваги, які найкраще відповідають набору навчальних прикладів, тобто мінімізуючи функцію втрат між спостережуваними прикладами тренувань (та іншими попередніми обмеженнями або знаннями) та передбаченими значеннями. При виборі того, який алгоритм використовувати для даної задачі (і даної цільової функції), слід брати до уваги взаємозв'язок між величиною простору гіпотез, повнотою, кількістю доступних навчальних прикладів, попередніми знаннями, які володіють учні та можна припустити, що гіпотеза, що узгоджується з даними навчання, буде правильно узагальнюватися до невидимих прикладів.

Вибираючи, який алгоритм використовувати для даної проблеми (і заданої цільової функції), слід враховувати залежність між розміром простору гіпотез, його повнотою, кількістю наявних прикладів навчання, попередніми знаннями, якими володіє система. Можна сказати, що гіпотеза, яка відповідає даним про навчання, буде правильно узагальнена для небачених прикладів

Гіпотеза індуктивного навчання апроксимує цільову функцію над достатньо великим набором навчальних прикладів, а також апроксимує цільову функцію над іншими непоміченими прикладами.

Існує велика різноманітність моделей машинного навчання, всі мають різні попередні припущення щодо можливих відображень вводу-виводу або розподілу даних відповідно навчання з вчителем та без. Припущення зазвичай є необхідними, оскільки проблема недостатньо зрозуміла для машинного навчання, а даних про навчання, таким чином, недостатньо, щоб моделі могли знайти рішення самостійно. Наприклад, відображення може не існувати, або може бути недостатньо інформації або наявність шуму, що на практиці робить ідеально придатну модель неінформативною. Ці набори припущень для того, щоб зробити навчання можливим, називають

індуктивним зміщенням. Мітчелл [3] визначив індуктивне зміщення алгоритму навчання як "набір тверджень, які разом із навчальними прикладами дедуктивно тягнуть за собою наступні прогнози, зроблені системою". Таким чином, індуктивне зміщення є важливим фактором, оскільки описує, як система узагальнює спостереження прикладами навчання.

Вибираючи тип навчального досвіду з якого система буде навчатися, слід розглянути три важливі ознаки:

Прямий чи непрямий досвід навчання: у випадку прикладу гри в шахи навчання системи проводиться з окремих станів та послідовних прямих рухів або переміщення послідовностей та кінцевих результатів

Ступінь контролю системи над послідовністю прикладів навчання: наприклад, дано інформаційну дошку з правильним переміщеннями для кожного проти самостійно вибраних станів де система запитує правильний хід при зустрічі або особливо заплутані стани проти повного контролю над станами та класифікаціями (наприклад, гра проти себе, відсутність участі вчителя).

Як репрезентативні приклади навчання мають розподіл підсумкових тестових прикладів, за якими оцінюється кінцева продуктивність системи. Хоча навчання є найбільш надійним, коли ці розподіли подібні (більшість теорій машинного навчання спирається на припущення, що вони однакові), та часто відрізняються в реальних програмах через практичні обмеження.

Оскільки це все може мати суттєвий вплив на результативність навчання, тому це все важливі складові проектування навчальної системи. У машинному навчанні часто корисно, як каже Мітчелл [3], «звести проблему підвищення продуктивності P при завданні T до проблеми вивчення якоїсь конкретної цільової функції», наприклад, вибір того, який хід вибере наступний (із набору законних кроків, враховуючи стан дошки). Процес вивчення цільової функції часто називають наближенням функції,

тому що часто очікуємо, що алгоритм дізнається лише деяке наближення до цільової функції.

1.2. Поняття хвороби Альцгеймера

Хвороба Альцгеймера – це нейродегенеративне захворювання, яке викликає проблеми з поведінкою, пам'яттю та мисленням та є смертельним. Це найбільш поширена форма деменції, що становить близько 60% всіх випадків та одна з найбільш дорогих захворювань для суспільства [6]. У 2006 році від хвороби постраждало 26,6 мільйонів людей, і до 2050 року, за прогнозами, постраждає ще близько 115 мільйонів. Цей же звіт також вказує, що майже дві третини людей, які постраждали від деменції, живуть у країнах з низьким та середнім рівнем доходу. Ця статистика впливає з кількох причин, однією з яких є те, що пацієнти з деменцією в цих країнах в основному покладаються на неформальне лікування. Хоча деякі з симптомів можуть виглядати дещо подібно з типовими ознаками прогресуючого старіння, важливо відзначити, що хвороба Альцгеймера не є нормальною частиною старіння. Під час прогресування захворювання симптоми деменції поступово погіршуються.

В даний час не існує способу одужання від хвороби Альцгеймера. Мета полягає в тому, щоб уповільнити прогресування захворювання, поліпшити симптоми, вирішити проблеми поведінки і поліпшити якість життя. Існуючі методи лікування можуть тимчасово уповільнювати розвиток симптомів деменції, якщо захворювання діагностується на ранній стадії. Ефективне лікування та профілактика є дуже важливою довгостроковою метою, яка може дати пацієнтам порівняно кращі результати [17]. Тому рання діагностика є важливою задачею, яка має бути автоматизована.

Розроблення способів автоматизованої діагностики ґрунтується на аналізі МРТ-зображень. Сканування зображень головного мозку часто

використовується для виявлення інших причин симптомів, але також може бути показником того, чи присутня хвороба Альцгеймера.

1.2.1. Біомаркери структурних змін в головному мозку для аналізу МРТ-зображень

Симптоми, що виникають під час розвитку хвороби Альцгеймера, викликані змінами в головному мозку (тобто структурними порушеннями), що є чутливою особливістю захворювання. Гіпокампи осіб, які страждають хворобою Альцгеймера, атрофуються на ранніх стадіях захворювання – явище, яке можна надійно виявити за допомогою об'ємної МРТ для діагностичних цілей. Ця втрата нейронів і синапсів від захворювання призводить до чітко видимих відмінностей у тканині мозку. Захворювання регулярно характеризується дегенерацією кори головного мозку і гіпокампу, що призводить до атрофії кісткової тканини в темпоральній, фронтальній і тім'яній областях. Шлуночки збільшені порівняно зі здоровими індивідуумами. Мікроскопічні зміни в головному мозку починаються задовго до появи перших ознак втрати пам'яті до клінічного діагнозу хвороби Альцгеймера. На рис. 1.1 та рис. 1.2 зображені зміни в головному мозку людини під час розвитку хвороби Альцгеймера [3].




Рис. 1.1. Зразок мозку здорової людини

МРТ дозволяє дослідникам і клініцистам оцінювати ці структурні зміни в мозку, асоційовані з хворобою Альцгеймера.




Рис. 1.2. Зразок мозку людини з хворобою Альцгеймера

Існують також інші модальності, такі як техніка візуалізації, яка чітко показує форми бета-амілоїдних відкладень в мозку. Однак ця техніка більш інвазивна, оскільки вимагає контрастної речовини, а саме радіоактивного цукру, який всмоктується в мозку пацієнта. Крім того, він набагато новіший, а не доступний як МРТ [13].

1.3. Магнітно-резонансна томографія

Магнітно-резонансна томографія на відміну від звичайних рентгенівських сканів не залежить від іонізуючого випромінювання. Техніка візуалізації може генерувати тривимірні зображення на будь-якій глибині і в будь-якому напрямку та набагато перевершує інші інструменти обробки неінвазивних зображень з високою роздільною здатністю і є діагностичним способом виявлення м'яких тканин. Хоча це зазвичай не потрібно, пацієнтам МРТ іноді вводять контрастну речовину, щоб зробити аномалії (наприклад, пухлини) більш ясними [4].

Магнітно-резонансна томографія працює за допомогою радіохвиль для перенаправлення осей прядильних протонів, які є ядрами атомів водню (від води в тілі), в той час як всередині магнітного поля генерується пропускання електричного струму через котушки.

Основним магнітом в машині (навколо пацієнта) є надпровідний електромагніт: електромагніт, який не має опору електриці і відсутній теплоутворення (завдяки охолодженню рідким гелієм).

На рис. 1.3 зображений пацієнт розташований таким чином, що частина тіла знаходиться всередині ізоцентру магнітного поля.




Рис. 1.3. МРТ-сканер

Повернутий сигнал потім перетворюється на електричний струм, який оцифровується сканером та генерує ряд зображень, кожен з яких показує фрагмент тіла [5].

1.3.1. Набір даних для дослідження хвороби Альцгеймера

Група дослідників нейровізуалізації хвороби Альцгеймера (ADNI) – це тривала спільнота, яка має на меті розробити клінічні, візуальні, генетичні та біохімічні біомаркери для раннього виявлення та відстеження хвороби Альцгеймера [1].

Всесвітній проект надає дослідникам достовірні клінічні дані про хворобу Альцгеймера, які мають на меті краще зрозуміти патологію хвороби Альцгеймера за допомогою біомаркерів, сподіваючись, що це дозволить раніше діагностувати хворобу Альцгеймера, надати дані клінічних випробувань з метою підтримки нових методів дослідження, що стосуються втручання, профілактики та лікування захворювання і продовжувати та вдосконалювати обмін своєю базою даних. Метою було розробити більш точні методи діагностики для виявлення хвороби

Альцгеймера на ранній стадії та визначення патології за допомогою біологічних маркерів. Було успішно розроблено детективні методи ранньої стадії для хвороби Альцгеймера, стандартизовано методи клінічних тестів та створено свою базу даних наборів даних, що містять зображення сканування мозку. В моєму магістерському дослідженні я використовую частину даних МРТ-зображень з набору даних ANDI [1].

1.4. Висновки

У першому розділі описана теорія класифікації зображень та розглянуто основи досліджень хвороби Альцгеймера. Була представлена відповідна інформація щодо деменції, технології магнітно-резонансної томографії та отриманих зображень. Після цього було описано як організації пов'язані з дослідженням хвороби Альцгеймера сприяють дослідженню хвороби – наприклад: Ініціативна група нейровізуалізації хвороби Альцгеймера (ANDI), з якої було взято набір даних, використаних у цій роботі.

2. СПОСОБИ МАШИННОГО НАВЧАННЯ ТА ЗГОРТКОВА НЕЙРОННА МЕРЕЖА

2.1. Способи машинного навчання

2.2.1. Штучні нейронні мережі

Штучні нейронні мережі – це математичні програмні моделі, що забезпечують надійні загальні методи навчання та побудовані за принципом функціонування біологічних нейронних мереж. Частково натхненні складними взаємопов'язаними нейронами, що складають біологічні системи (наприклад, центральної нервової системи тварин, зокрема мозку) та складаються з набору взаємопов'язаних одиниць, кожен з яких приймає реальну одиницю на вхід та виробляє реальну одиницю на вихід (яка, в свою чергу, може використовуватися як вхід до інших одиниць). Однак є складні аспекти біологічних нейронних систем, які штучні нейронні мережі не

моделюють, а також особливості систем, які можуть бути невідповідними для біологічних систем, які видають єдине постійне значення. Штучні нейронні мережі не утворюють спрямований цикл та є багатошаровими мережами, що подають інформацію від вхідних вузлів (через будь-які можливі приховані вузли) до вихідних вузлів.

Одним з дуже простих типів мережі подачі даних є перцептрон, який є особливим видом штучного нейрона та виконує бінарну класифікацію. На рис. 2.1 зображений перцептрон.




Рис. 2.1. Перцептрон

Перцептрон приймає вектор реального значення як свій вхід і обчислює лінійну комбінацію всіх вхідних даних, обчислюючи зважену суму відповідних ваг та аналогів у векторі реально оцінених констант на яких застосовується зміщення. Потім передаються функції активації, яка у випадку сприймання є функцією знаку. Функція знаку працює таким чином: якщо результат перевищує деякий поріг, перцептрон виводить 1, а в іншому випадку виводить мінус 1. Існує також альтернативна конструкція перцептронів для цих примітивних одиниць (тобто нейронів), таких як лінійні та сигмоподібні одиниці.

Одношарові перцептрони здатні лише вивчати лінійно роздільні шаблони, роблячи їх здатними представляти примітивні булеві функції. Булеві функції, такі як XOR, не можуть бути представлені одним

перцептроном. З іншого боку, багатошарові перцептрони здатні вивчати лінійно нероздільні шаблони завдяки своїй нелінійній функції активації (наприклад: гіперболічна дотична функція $\tanh()$, логістична функція або softmax). Мережа перцептронів повинна мати можливість представляти кожен булеву функцію, хоча ця мережа була б дуже великою і використовувала б велику кількість нейронів.

Процес навчання складається з коригування ваг мережі для мінімізації функції витрат (наприклад: середня квадратична помилка, перехресна ентропія). Наприклад, багатошарові перцептрони навчаються за допомогою стандартного алгоритму зворотного розповсюдження, оновлюючи ваги за допомогою градієнтного спуску, щоб найкращим чином підігнати навчальний набір пар вхід-вихід. Хоча існує багато стратегій навчання нейронних мереж, найбільш популярними стратегіями є переважно методи, засновані на градієнтах.

Штучні нейронні мережі добре підходять для проблем навчання, які стосуються складних даних сенсорів (наприклад: аудіо та зображень) та були успішно застосовані до безлічі проблем, і в даний час дуже популярні, а також ефективні для певних типів проблем у різних областях, таких як автономне управління транспортними засобами, розпізнавання обличчя, обробка природних мов, медична діагностика, обмін даними та автоматизовані торгові системи. Останнім часом спостерігається відновлення інтересу до нейронних мереж, значною мірою завдяки появі глибокого навчання.

2.2.2. Метод опорних векторів

Метод опорних векторів (SVM) – це метод аналізу даних для класифікації особливостей за допомогою моделей з керованим навчанням з пов'язаними алгоритмами навчання, які називаються опорно-векторними машинами, формально визначений як розділення площини гіпер-планом. Іншими словами, з даними мічених навчальних даних

(контрольоване навчання) алгоритм виводить оптимальний гіпер-план, який класифікує нові приклади. У двовірному просторі гіперплан – це лінія, що розділяє площину на дві частини.

Завдання алгоритму – знайти гіперплан у N-вимірному просторі, де N – це кількість ознак, що чітко класифікує точки даних. На рис. 2.2 зображені можливі гіперплани.




Рис. 2.2. Можливі гіперплани

Для розділення двох класів даних існує багато можливих гіперпланів, які можна було б вибрати. Мета – знайти площину, яка має максимальний запас, тобто максимальну відстань між точками даних обох класів. Максимальне обмеження відстані забезпечує деяке підкріплення, щоб майбутні точки даних можна було класифікувати з більшою впевненістю.




Рис. 2.3. Класифікація точок даних

Гіперплани – це межі рішення, які допомагають класифікувати точки даних. Точки даних, що падають з будь-якої сторони гіперплана, можна віднести до різних класів. Також розмірність гіперплана залежить від кількості ознак. Якщо кількість вхідних функцій дорівнює 2, то гіперплан становить одну лінію. Якщо кількість вхідних ознак дорівнює 3, то гіперплан стає двовимірною площиною. Важко уявити, коли кількість функцій перевищує три.

Вектори підтримки – це точки даних, які ближче до гіперплану і впливають на положення та орієнтацію гіперплана. Використовуючи ці вектори підтримки, максимально збільшуємо запас класифікатора.

В алгоритмі SVM прагнемо домогтися максимальної межі між точками даних та гіперпланом та апроксимізувати функцію втрат, яка допомагає максимізувати вигоду.

2.2.3. Згорткова нейронна мережа

Згорткова нейронна мережа (CNN) – алгоритм глибокого навчання, який може приймати вхідне зображення, присвоювати навчальні ваги різним об'єктам на зображенні та мати можливість відрізнати зображення один від одного. Попередня обробка значно нижча порівняно з іншими алгоритмами класифікації.

Класична архітектура нейронної мережі виявилася неефективною для виконання завдань з комп'ютерного зору. Зображення представляють собою великий вхід для нейронної мережі (вони можуть мати сотні чи тисячі пікселів і до 3 кольорових каналів). У класичній повністю підключеній мережі для цього потрібна величезна кількість з'єднань та мережевих параметрів.

Архітектура згорткових нейронних мереж використовується для ефективного розпізнавання зображень, де чергуються згорткові шари (англ.

convolutions) з нелінійними функціями активації (ReLU або гіперболічний тангенс \tanh) і шари об'єднання або підвибірки (pooling layers).

Згорткова нейронна мережа використовує той факт, що зображення складається з менших деталей або особливостей, і створює механізм аналізу кожної особливості ізольованим, який інформує рішення про зображення в цілому.

У складі згорткової мережі також існує повністю пов'язаний шар, який приймає кінцевий результат процесу об'єднання і приймає рішення про класифікацію.

Архітектура згорткової нейронної мережі зображена на рис. 2.4 є аналогічною схемі зв'язку нейронів у людському мозку. Окремі нейрони реагують на подразники лише в обмеженій області зорового поля, відомої як рецептивне поле. Колекція таких полів перекривається, щоб охопити всю зорову зону.

Згорткові нейронні мережі мають кілька типів шарів:

- Згортковий шар – “фільтр” передає зображення, скануючи кілька пікселів одночасно і створюючи карту характеристик, яка передбачає клас, до якого належить кожна функція.
- Шар об'єднання (пониження) зменшує кількість інформації в кожній функції, отриманої в згортковому шарі, зберігаючи найважливішу інформацію (зазвичай це кілька раундів згортки та об'єднання).

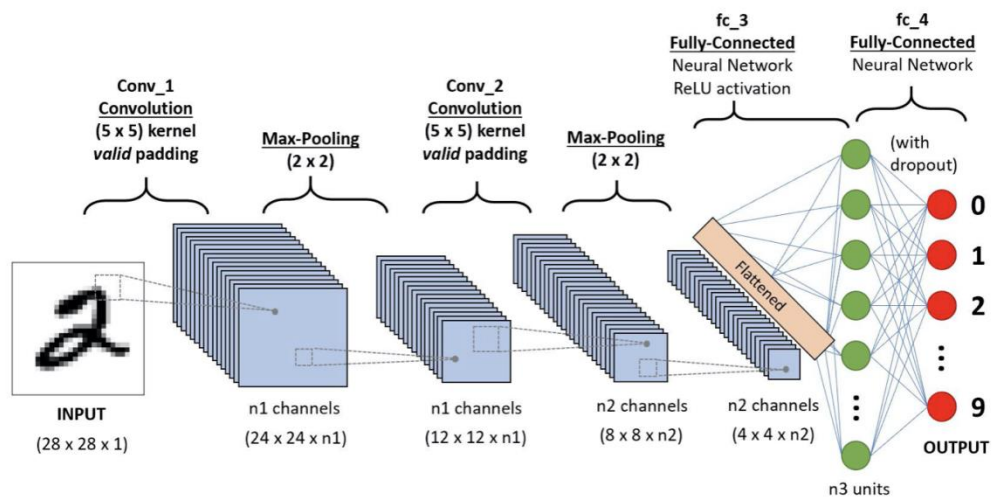


Рис. 2.4. Архітектура згорткової мережі

- Повністю з'єднаний вхідний шар – приймає вихід попередніх шарів, «розгладжує» їх і перетворює їх в єдиний вектор, який може бути входом для наступного етапу.
- Перший повністю пов'язаний шар – приймає вхідні дані з аналізу функцій і застосовує ваги для прогнозування правильної мітки.
- Повністю підключений вихідний шар – дає кінцеві ймовірності для кожної мітки.

Загалом глибинні нейронні мережі показали хороші результати щодо важливих стандартизованих наборів даних в останні роки. Тому було прийнято рішення застосувати згорткові нейронні мережі для попереднього виявлення хвороби Альцгеймера. Більш детально про архітектуру буде описано у наступному підрозділі. Існують різноманітні архітектури CNN, які були ключовими в побудові алгоритмів, які допоможуть розвитку штучного інтелекту в майбутньому.

2.2. Основні етапи навчання нейронної мережі

2.2.1. Розклад зображення у вектор

Зображення – це матриця значень пікселів. Тому можна просто вирівняти зображення (наприклад, матрицю зображень 3x3 у вектор 9x1 як

зображено на рис. 2.5) і подати його на багаторівневий персептрон для цілей класифікації.




Рис. 2.5. Розклад зображення у вектор

У випадках надзвичайно базових бінарних зображень метод може показувати середній показник точності при виконанні прогнозування класів, якщо мова йде про складні зображення, що мають піксельну залежність протягом усього часу, то середній показник точності значно менший.

Згорткова нейронна мережа може успішно фіксувати просторові та часові залежності у зображенні за допомогою застосування відповідних фільтрів. Архітектура забезпечує краще пристосування до набору даних зображення за рахунок зменшення кількості задіяних параметрів та повторного використання ваг. Іншими словами, мережу можна навчити краще розуміти зображення.

2.2.2. Вхідне зображення

RGB-зображення – це адитивна колірна модель, що описує спосіб синтезу кольору, за якою червоне, зелене та синє світло накладаються разом, змішуючись у різноманітні кольори. Широко застосовується в техніці, що відтворює зображення за допомогою випромінювання світла.

На рис. 2.6 маємо RGB-зображення, яке було розділене трьома кольорами – Червоним, Зеленим та Синім – це ряд таких кольорових просторів, у яких існують зображення.

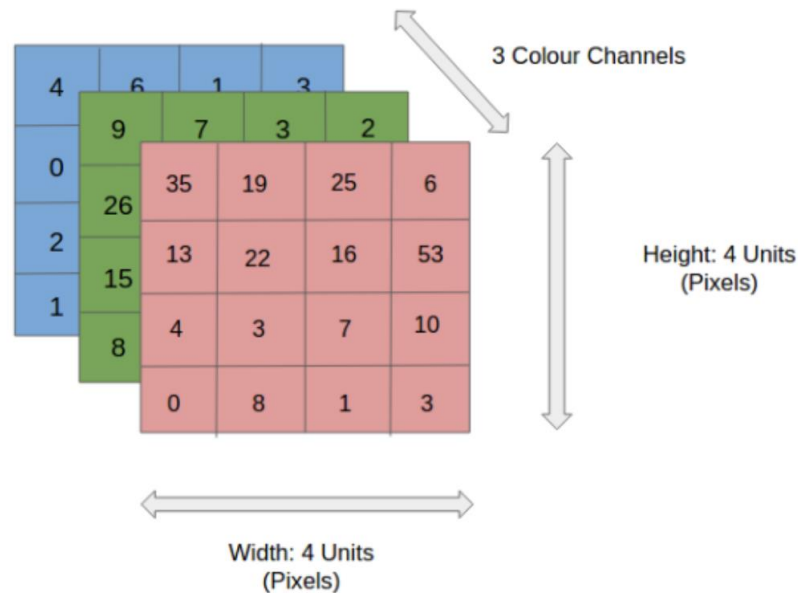


Рис. 2.6. Розділення вхідного зображення

Коли зображення мають розмірність близько 7680×4320 , то їх значно важче обробляти. Роль CNN полягає в тому, щоб зменшити зображення у форму, яку легше обробляти, не втрачаючи особливостей, які є критичними для отримання хорошого прогнозу. Це важливо, коли потрібно створити архітектуру, яка не тільки добре засвоює функції, але також масштабується до масивних наборів даних.

2.2.3. Згортковий шар

Головним шаром згорткової нейронної мережі беззаперечно можна вважати шар згортки [4], робота якого є основою даної мережі. Параметри шару згортки складаються з набору фільтрів для навчання. Наприклад стандартний фільтр першого шару нейронної мережі може мати розмір зображення = 5 (Висота) x 5 (Ширина) x 1 (Кількість каналів, наприклад, RGB). На рис. 2.7 зелений розділ показує вхідне зображення 5x5x1. Елемент, що бере участь у проведенні операції згортання в першій частині згорткового шару, називається ядром або фільтром, представленим жовтим кольором. Ядро – це матриця 3x3x1.




Рис. 2.7. Особливість згортки зображення

Ядро зміщується в 9 разів через довжину кроку 1, кожен раз виконуючи операцію множення матриці, над якою лежить ядро.




Рис. 2.8. Рух ядра

Фільтр рухається вправо з певним значенням «Крок», поки не розбере повну ширину. Перемістившись, переходить до початку (зліва) зображення з тим самим значенням «Крок» і повторює процес, поки не буде пройдено все зображення.

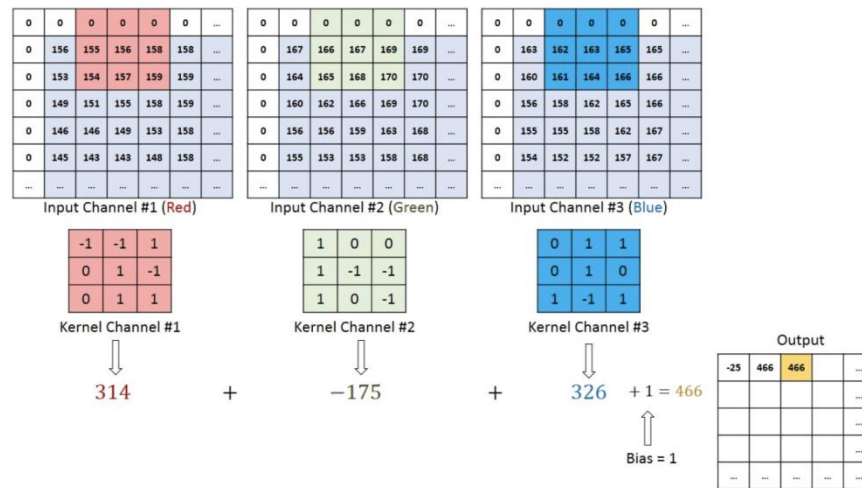


Рис. 2.9. Операція згортки

У випадку з зображеннями з декількома каналами (наприклад, RGB) ядро має ту саму глибину, що і для вхідного зображення. Матричне множення виконується між K_n і I_n стеком ($[KC1, IC1]; [KC2, IC2]; [KC, IC3]$) зображених на рис. 2.9, і всі результати підсумовуються з ухилом, щоб сформувати один глибинний канал зведеного виходу функції.

Завдання операції згортання – витягнути із вхідного зображення функції високого рівня. CNN не повинен обмежуватися лише одним згортковим шаром. Зазвичай перший шар несе відповідальність за фіксацію функцій низького рівня, таких як краї, колір, орієнтація градієнта тощо. З доданими шарами архітектура також адаптується до функцій високого рівня, сформувавши нейронну мережу, яка буде мати краще розуміння зображень у наборі даних.

Операції має два типи результатів: один, у якому шар згортки зменшується в розмірності порівняно з вхідним, а другий, у якому розмірність або збільшується, або залишається однакою.

Це можна зробити застосувавши Valid Padding у випадку першого, або ж Same Padding у випадку останнього.

Якщо збільшити розмір зображення $5 \times 5 \times 1$ на зображення $6 \times 6 \times 1$, а потім накласти на нього ядро $3 \times 3 \times 1$, отримаємо матрицю яка має в розмірі $5 \times 5 \times 1$. Звідси і назва - Same Padding.





Рис. 3. Операція Same Padding

З іншого боку, якщо виконати ту саму операцію застосувавши Valid Padding, то отримаємо матрицю, яка має розміри самого ядра $3 \times 3 \times 1$.



-+Рис. 3.1. Операція Valid Padding

2.2.4. Шар об'єднання

Шар об'єднання зображений на рис. 3.1 відповідає за зменшення просторових розмірів об'єднаної функції. Це зменшеннює обчислювальну потужність, необхідної для обробки даних за рахунок зменшення

розмірності. Крім того, це корисно для видалення домінуючих рис, які є позиційно інваріантними, таким чином підтримуючи процес ефективної підготовки моделі.

3.0	3.0	3.0
3.0	3.0	3.0
3.0	2.0	3.0

3	3	2	1	0
0	0	1	3	1
3	1	2	2	3
2	0	0	2	2
2	0	0	0	1

Рис. 3.1. Шар об'єднання

Існує два типи об'єднання: максимальне об'єднання та середнє об'єднання. Максимальне об'єднання повертає максимальне значення з частини зображення, охопленого ядром. Середнє об'єднання повертає середнє значення всіх значень з частини зображення, охопленої ядром. Максимальне об'єднання також виконує функції зниження шуму або взагалі відкидає шумні активації разом зі зменшенням розмірності.




Рис. 3.2. Типи об'єднання

З іншого боку, середнє об'єднання просто виконує зменшення розмірності. Отже, можна сказати, що максимальне об'єднання працює набагато краще, ніж середнє об'єднання.

Згорнутий шар і шар об'єднання разом утворюють i -й шар конволюційної нейронної мережі. Залежно від складності зображень, кількість таких шарів може бути збільшена для захоплення деталей низького рівня ще більше, але ціною більшої обчислювальної потужності.

Після того як закінчився вищесказаний процес, модель успішно зрозуміла особливості зображення.

2.2.5. Техніка регуляризації *Dropout*

Одна з головних проблем використання глибоких нейронних мереж – це перенавчання (англ. *overfitting*) [6]. Техніку *Dropout* можна описати як метод, який використовується для запобігання перенавчання та певної адаптації нейронів до вхідних даних шляхом встановлення вихідного сигналу будь-якого нейрона у значення нуля з ймовірністю p . У статті [10] запропонували випадкове розміщення нейронів, який є ефективним способом середнього розміщення багатьох великих нейронних мереж, тим самим зменшуючи надмірне перенавчання. Це перешкоджає складному пристосуванню даних про навчання. Техніка працює, встановлюючи випадково вибрану підмножину активацій на нуль у межах кожного шару, тобто випадковим чином опускаючи кожну приховану одиницю з ймовірністю 0,5 щоразу, коли буде представлений навчальний приклад. Тому прихований блок не може покладатися на присутність інших прихованих одиниць. Хороший спосіб зменшити помилку на тестовому наборі – це середня оцінка прогнозів, отриманих дуже великою кількістю різних мереж. Замість того, щоб навчати багато окремих мереж та застосовувати кожну до тестових даних, можна “навчити величезну кількість різних мереж у розумний час”, використовуючи регуляризацію.

Відзначають, що використання середньої мережі є еквівалентом "середньому геометричному розподілу ймовірностей по мітках, передбаченому всіма можливими мережами".

Графічне представлення техніки Dropout рис 3.3, взяте зі статті [6], в якій техніка була вперше представлена




Рис. 3.3. Графічне представлення техніки Dropout

За словами авторів техніки у стандартній нейронній мережі похідна, отримана кожним параметром, повідомляє цьому ж параметру, як він повинен змінитися, щоб, з огляду на діяльність інших блоків, мінімізувати функцію втрат. Тому блоки можуть змінюватися, виправляючи при цьому помилки інших блоків.

2.2.6. Алгоритм зворотного поширення

Алгоритм зворотного поширення (Backpropagation) є методом навчання для штучних нейронних мереж, який є узагальненням правила дельти до багатошарової прямої мережі. Зазвичай використовується з методами оптимізації, наприклад, градієнтним спуском. Зворотне розповсюдження здійснюється шляхом виправлення помилок сигналів від кожного мережевого рівня до попереднього, здійснюючи корекцію ваг в напрямку, що викликає найбільшу зміну виходу. Найбільш можливе призначення ваги не гарантується, оскільки може опинитися в локальному оптимумі і там є ризик призупинити процедуру в більш глибоких мережах.

Алгоритм зворотного поширення може містити цикли. Навчання відповідає вибору ваги для кожного з ребер у графі. Алгоритм намагається звести до мінімуму квадратичну помилку, намагаючись вибрати ваги, які найкраще відповідають набору навчальних прикладів, тобто мінімізувати функцію втрат.

Існує ризик «перенасичення», тобто нейронна мережа вивчає дані занадто добре, включаючи нерелевантні деталі, які відсутні за межами навчального набору. Але це можна подолати, використовуючи певною мірою більшу кількість даних, а також застосуванням методів регуляризації.

2.2.7. Класифікація зображень

В згорткових мережах повнозв'язний шар (класифікатор) [9] нейрони має зв'язок з усіма функціями активації з попереднього шару. Активації шарів класифікації можуть бути обчислені за допомогою множення матриць, що супроводжується зміщенням. Відмінність між шаром класифікації і шаром згортки полягає у тому, що нейрони шару згортки з'єднані тільки з локальною областю на вході та нейрони цього шару можуть спільно використовувати параметри. Однак нейрони в обох шарах, незважаючи на свої особливості, підраховують скалярний добуток, тому їх функціональна форма ідентична. Більш того, можна виконати конвертацію між повнозв'язним і згортковим шарами.

Додавання повністю з'єданого шару – це простий спосіб вивчення нелінійних комбінацій особливостей високого рівня, представлених результатом згорткового шару. Повно-зв'язаний шар вивчає нелінійну функцію в цьому просторі.

Тепер, коли вхідне зображення перетворилося у відповідну форму для багаторівневого персептрона, вирівнюємо зображення у вектор як було сказано раніше.

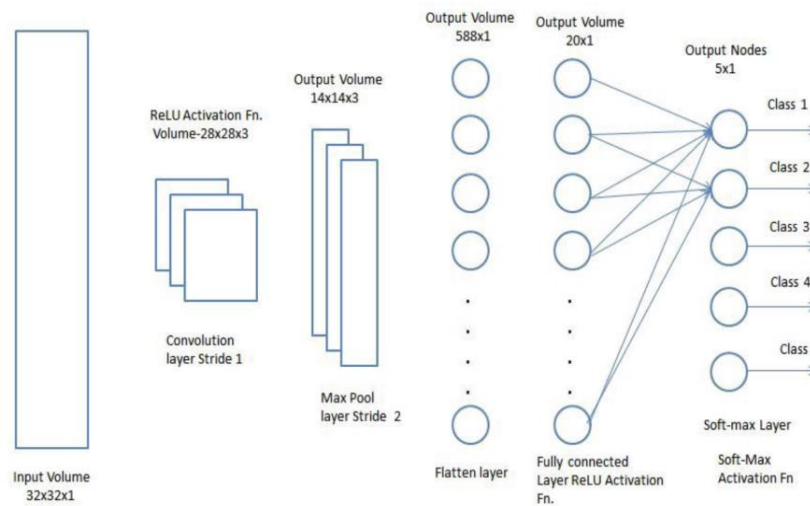


Рис. 3.3. Повно-зв'язний шар

Зворотне розповсюдження застосовується до кожної ітерації тренувань. Протягом серії епох модель здатна розрізнити домінуючі та певні низькорівневі риси зображень та класифікувати їх за допомогою методики класифікації Softmax.

Популярним вибором класифікатору є класифікатор Softmax, який має зовсім іншу функцію втрат та в основу якого покладено нормовану експоненційну функцію. Цей класифікатор по своїй суті є узагальненим класифікатором двійкової логістичної регресії. На відміну від методу опорних векторів, який обчислює результати вектору як оцінки для кожного класу, класифікатор Softmax керований трохи більш інтуїтивним підходом, а також має імовірнісну інтерпретацію.

Класифікатор повинен запам'ятовувати всі навчальні дані та зберігати їх для подальших порівнянь із даними з тестового запуску. Це дуже ресурсозатратно, оскільки набори даних можуть бути розміром у гігабайтах.

2.3. Показники нейронної мережі

Тести діагностики включають різного роду інформацію, таку як: медичні тести (наприклад, аналіз крові, рентген), медичні ознаки (відбитки пальців, ознаки захворювання легенів) або симптоми (наприклад, біль за певною ознакою). Рішення лікаря щодо лікування покладаються на

діагностичні тести, що робить точність діагнозу важливою в медичній допомозі. На щастя, атрибути діагностичних тестів можна виміряти. Для даного захворювання, виходячи з цих ознак, можна вибрати найкращий тест. Чутливість, специфічність та точність широко використовуються статистикою для опису діагностичного тесту. Зокрема, вони використовуються для кількісної оцінки того, наскільки хорошим та надійним є тест. Чутливість оцінює наскільки хороший тест при виявленні позитивного захворювання. Специфічність оцінює наскільки вірогідними можуть бути виключені пацієнти без захворювання. Для оцінки тесту використовують криву ROC – це графічне зображення взаємозв'язку як чутливості та специфічності, яка допомагає визначити оптимальну модель шляхом визначення найкращого порогу діагностичного тесту. Точність вимірює наскільки правильний діагностичний тест визначає та виключає заданий стан. Це допомагає краще зрозуміти, коли використовувати, як застосовувати та як інтерпретувати результати. Важливість та популярність цієї статистики вимагає ретельного огляду разом із практичними прикладами.

Далі будуть описані концепції чутливості, специфічності та точності в контексті діагностики захворювання: починаючи з огляду визначень, способів обчислення чутливості, специфічності та точності, пов'язаного з ними 95% довірчого інтервалу та аналізу ROC; загальних питань інтерпретації результатів чутливості, конкретності та точності.

2.3.1. Чутливість, специфічність, точність та довірчий інтервал

Існує кілька термінів, які зазвичай вживаються поряд з описом чутливості, специфічності та точності. Вони істинно позитивні (TP), справжні негативні (TN), хибнонегативні (FN) та хибнопозитивні (FP). Якщо у пацієнта виявлено наявність захворювання, даний діагностичний тест також вказує на наявність захворювання - результат діагностичного тесту вважається справжнім позитивним. Аналогічно, якщо у пацієнта

виявлено відсутність захворювання, діагностичний тест дозволяє припустити, що захворювання також відсутнє, результат тестування справді негативний (TN). І справжній позитивний, і справжній негативний свідчать про послідовний результат між діагностичним тестом і доведеним станом (його також називають еталоном істини).

Однак жоден медичний тест не є ідеальним. Якщо діагностичний тест вказує на наявність захворювання у пацієнта, який насправді не має такого захворювання, результат тесту є хибнопозитивним (FP). Так само, якщо результат діагностичного тесту говорить про те, що хвороба точно відсутня для пацієнта із захворюванням, результат тесту є хибнонегативним (FN). І хибнопозитивний, і хибнонегативний свідчать про те, що результати тестування протилежні фактичному стану.

Чутливість, специфічність і точність описані в термінах TP, TN, FN та FP.

- Чутливість = $TP / (TP + FN)$ = (Кількість справжньої позитивної оцінки) / (Кількість усієї позитивної оцінки)
- Специфічність = $TN / (TN + FP)$ = (Кількість справжньої негативної оцінки) / (Кількість усієї негативної оцінки)
- Точність = $(TN + TP) / (TN + TP + FN + FP)$ = (Кількість правильних оцінок) / Кількість усіх оцінок

Як запропоновано вище наведеними рівняннями, чутливість – це частка справжніх позитивних результатів, які правильно ідентифікуються діагностичним тестом. Він показує, наскільки хороший тест на виявлення захворювання. Специфічність – це частка справжніх негативів, правильно визначених діагностичним тестом. Це говорить про те, наскільки хороший тест при виявленні нормального (негативного) стану. Точність – це частка справжніх результатів, чи справжніх позитивних, так і справжніх негативних, у сукупності.

Числові значення чутливості представляють вірогідність діагностичного тесту ідентифікувати пацієнтів, у яких насправді є

захворювання. Чим вище числове значення чутливості, тим менш вірогідний діагностичний тест повертає хибнопозитивні результати. Наприклад, якщо чутливість тесту становить 99%, це означає: що є 99% шансів, що цей пацієнт буде ідентифікований як позитивний.

Числове значення специфічності представляє ймовірність тестового діагностування конкретного захворювання без надання хибнопозитивних результатів. Наприклад, якщо специфічність тесту становить 99%, це означає: що є 99% шансів, що цей пацієнт буде ідентифікований як негативний.

Тест може бути дуже конкретним, не бути чутливим, або він може бути дуже чутливим, не будучи конкретним. Обидва фактори однаково важливі. Хорошим тестом є такий, що має як високу чутливість, так і специфічність. Хороший приклад тесту з високою чутливістю та специфічністю – тест на вагітність. Позитивний результат тесту на вагітність майже напевно говорить про те, що суб'єкт, який склав тест, вагітний. Негативний результат майже напевно виключає можливість вагітності.

Окрім наведеного вище рівняння, точність можна визначити за чутливістю та специфічністю, де відома поширеність. Поширеність – це ймовірність захворювання в популяції в даний момент часу:

Точність = (чутливість)*(поширеність) + (специфічність)*(1 - поширеність).

Чисельне значення точності представляє частку справжніх позитивних результатів (як справжніх позитивних, так і справжніх негативних) у вибраній сукупності. Однак, варто згадати, що з рівняння точності впливає, що навіть якщо чутливість і специфічність високі, скажімо, 99%, це не дозволяє припустити, що точність тесту однаково висока. Крім чутливості та специфічності, точність визначається також тим, наскільки поширене захворювання у вибраної популяції. Діагностика рідкісних станів у населення, що цікаво, може спричинити високу

чутливість та специфічність, але низьку точність. Точність потрібно трактувати обережно.

Довірчі інтервали можна використовувати як стандартні методи пропорцій. Два типи довірчих інтервалів, як правило, побудовані на основі пропорцій: асимптотичний та точний довірчий інтервал. Точний довірчий інтервал будується за допомогою біноміального розподілу для досягнення точної оцінки. Асимптотичний інтервал довіри обчислюється, приймаючи нормальне наближення розподілу вибірки. Вибір цих двох типів довірчого інтервалу залежить від того, чи є пропорція вибірки хорошим наближенням до нормального розподілу. Якщо кількість подій дуже мала або якщо розмір вибірки дуже малий, нормальне припущення не може бути виконане. Таким чином, бажано мати точний довірчий інтервал.

2.4. Висновки

У другому розділі розглянуті відповідні галузі машинного навчання та їх методики. Сюди входять сучасні підходи, такі як глибинне навчання та пов'язані з ними методи, які виявилися ефективними та методи машинного навчання, що застосовуються в дослідженнях, а також з підходами, які дають найкращі результати щодо проблем, які стосуються медичних зображень та, зокрема, хвороби Альцгеймера.

Метод опорних векторів (*Support Vector Machine, SVM*) відноситься до групи граничних методів та визначає класи за допомогою границь областей. За допомогою даного методу розв'язуються задачі бінарної класифікації. В основі лежить поняття площини рішень. Згорткові нейронні мережі (*Convolutional Neural Networks, CNN*) – це категорія глибоких нейронних мереж, які є ефективними для розпізнавання зображень та класифікації. Згорткова нейронна мережа дозволяє зменшити кількість інформації, що зберігається в пам'яті, за рахунок застосування спеціальної операції згортки та дозволяє обробляти зображення високої роздільності та виділити у зображенні такі ознаки, як ребра, контури або грані. На наступному рівні

оброблення з цих ребер і граней можна розпізнати повторювані фрагменти текстур, які надалі можуть скластися у фрагменти зображення.

Згорткові нейронні мережі активно застосовуються в медицині для класифікації симптомів хвороб.

3. СПОСІБ ПОКРАЩЕННЯ ТОЧНОСТІ КЛАСИФІКАЦІЇ ТА РОЗРОБЛЕННЯ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ

3.1. Алгоритм роботи програми

В цьому розділі описуються етапи, які необхідні для розроблення програмного забезпечення для автоматизованого виявлення хвороби Альцгеймера шляхом аналізу медичних зображень за допомогою згорткових нейронних мереж та дається відповідь на головне питання: як краще навчити нейронну мережу для раннього виявлення хвороби Альцгеймера з високою точністю.

Для досягнення успішних результатів були запропоновані наступні кроки роботи алгоритму програми:

Зменшення розмірності зображень: Оскільки випадки в наборі даних були високо-розмірними, потрібна певна форма зменшення розмірів, щоб зробити навчання можливим.

Об'єднання діагностичних груп: Для полегшення класифікації зображень та прискорення роботи алгоритму.

Сегментація зображень: Використати різні варіації сегментації зображень для зменшення області інтересів для класифікатора.

Навчання за допомогою декількох підходів: Методом опорних векторів, який мав перспективні результати в попередніх дослідженнях. та впровадити згорткову нейронну мережу, яка виявилася дуже точним щодо проблем з розпізнаванням структурних зображень.

Порівняти результатів: Виявити конфігурацію яка призводить до найменшої помилки класифікації та порівняти з минулими відповідними дослідженнями.

3.2. Минулі запроновані алгоритми

Загалом, метод опорних векторів (SVM) має меншу помилку класифікації зображень, ніж інші класифікатори. Дослідник Клоппель [4] спочатку використовував критерії для вибору найбільш передбачуваних ознак, а потім застосовував класифікатор для діагностики зображень здорових та хворих пацієнтів з хворобою Альцгеймера, використовуючи МРТ-зображення мозку. У цьому дослідженні він досяг точності 86,0%, чутливості 84,6% та специфічності 87,8%. Дослідник Нір [6] використовував метод моделювання волоконного тракту для вилучення особливостей зображення та застосовував метод опорних векторів для виявлення хвороби та досяг точності 86,2%, чутливості 88,0% та специфічності 89,2%. Згідно з останніми дослідженнями, метод опорних векторів дав найкращу точність класифікації серед інших класифікаторів.

Однак жоден метод попереднього виявлення хвороби Альцгеймера ще не досконалим. Тому є сенс застосувати нейронні мережі для вирішення даної проблеми.

Штучні нейронні мережі використовували для вирішення найрізноманітніших завдань, які важко вирішити за допомогою звичайного програмування на основі правил, щоб отримати більш високу чутливість та високу точність, ніж традиційний метод опорних векторів, що використовується в класифікації медичних зображень шляхом аналізу МРТ-зображень у попередніх дослідників. Дослідники Bianchini M та Scarselli F [10] вивчали різницю між дрібними та глибокими нейронними мережами у 2014 році. Відповідно до їх порівняння, глибинні нейронні мережі працюють краще. Крім того, вони підкреслили, що глибинні мережі можуть добре працювати з проблемами класифікації з не великими наборами даних. Порівнюють дрібні та глибинні нейронні мережеві архітектури для автоматичної класифікації зображень [16].

Згорткові нейронні мережі – це категорія глибинних нейронних мереж, які виявилися дуже ефективними в такій сфері, як розпізнавання особливостей та класифікація зображень. Крім того, це тип штучної нейронної мережі, що рухається вперед, який самостійно вивчає особливості зображення в згортковому шарі [8].

Раннє розпізнавання симптомів (попереднє виявлення) має вирішальне значення, оскільки ліки, що полегшують захворювання, будуть найбільш ефективними, якщо їх застосовувати на початку хвороби до того, як виникне незворотне ураження мозку.

В даний час не існує жодного способу одужання від хвороби Альцгеймера. Завданням лікарських засобів, що модифікують захворювання, є скоріше уповільнити прогресування захворювання, вирішити проблеми поведінки та покращити якість життя. Для уповільнення прогресування важлива рання діагностика хвороби Альцгеймера. Крім того, раннє діагностування допомагає людям з Альцгеймером та їх сім'ям різними

способами, такими як планування майбутнього, турбуватися про фінансові та правові питання та влаштовувати життя [7].

Підсумовуючи всі останні дослідження, було прийнято рішення впровадити згорткові нейронні мережі для автоматичного діагностування хвороби Альцгеймера шляхом аналізу МРТ-зображень для раннього виявлення хвороби з високою точністю.

3.3. Основні етапи для покращення класифікації зображень

3.3.1. Набір даних для навчання нейронної мережі

Зображення були взяті з набору даних всесвітнього проекту ANDI , який надає достовірні клінічні дані для дослідження принципу патології, профілактики та лікування хвороби Альцгеймера. Наскільки відомо, це найбільший доступний набір даних у своєму роді.

Першу версію бази даних було запущено у 2003 році Національним Інститутом Старіння (NIA), Національним інститутом біомедичної візуалізації та біоінженерії (NIBIB), Управлінням харчових продуктів та лікарських засобів (FDA), приватними фармацевтичними компаніями та некомерційними організаціями. Основною метою було перевірити, чи можна поєднувати серійну магнітно-резонансну томографію (МРТ), позитронно-емісійну томографію (ПЕТ), інші біологічні маркери та клінічну та нейропсихологічну оцінку для вимірювання прогресування легкого когнітивного порушення та ранньої хвороби Альцгеймера. Визначення чутливих та специфічних маркерів дуже раннього прогресування хвороби покликане допомогти дослідникам та клініцистам розробити нові методи лікування та контролювати їх ефективність, а також зменшити час та вартість клінічних випробувань. Головний дослідник цієї ініціативи доктор медичних наук в Каліфорнійському університеті Сан-Франциско, Майкл В. Вайнер. Набір даних ANDI – результат зусиль багатьох співдослідників із широкого кола академічних установ та

приватних корпорацій, а набір даних набирали з понад 50 сайтів у США та Канаді.

Набір даних також містить відповідні метадані для кожного сканування мозку, що включає інформацію, таку як стать, вік та діагностична група. Далі описані необхідні процедури для обробки зображень.

3.3.2. Зменшення розмірності зображень

Оскільки повна база даних ADNI порівняно велика та для простоти навчання нейронної мережі та проведення необхідних експериментів було взято приблизно дві тисячі зображень.

Набір даних містить 2340 тривимірних магнітно-резонансних зображень:

- 843 Хворі пацієнти
- 689 Легкі когнітивні порушення пацієнтів
- 808 Здорові пацієнти

Зображення з набору даних зазвичай мають дуже високу розмірність та в цьому випадку класифікатору знадобиться дуже великий обсяг часу для обробки всіх зображень з навчальних даних. Для забезпечити наявності декількох маркерів кожної можливої комбінації значень були потрібні деякі корегування даних для того, щоб зробити навчання практичним.

Щоб вирішити проблему було виконано аналіз основних компонентів (РСА), гістограму, сегментацію зображень та зменшення масштабу (перекомпонування зображень із меншою роздільною здатністю).

Оскільки випадки в наборі даних (тобто повні 3D-зображення) містять додаткову інформацію таку як шкіра, череп та простір навколо ознак, а також існують конкретні ключові ділянки мозку, які пов'язані з атрофією (крім загальної усадки головного мозку) у випадку хвороби Альцгеймера маємо те, що значна частина інформації на зображеннях не потрібна для цілей класифікації. Успішно зменшуючи розмірність даних, можливо

виграти з точки зору класифікації, а саме час навчання та розмір даних. Однак зменшення розмірності набору даних не обійшлося без підводних каменів. Якщо надто різко зменшити зображення, можна втратити цінну інформацію внаслідок цього класифікація зображень буде гірша.

Для зменшення розмірності даних кожен збережений фрагмент кожного зображення був нормалізований перед методом аналізу основних компонентів та був нанесений на зрізи, витягуючі по 20 компонентів. Для подальшого зменшення розміру набору даних, зберігався лише кожен 4-й фрагмент кожного зображення. Це ефективно зменшило розміри кожного примірника з 192x192x160 (після початкового розміру) до 48x192x20. Ця варіація включала загалом 1850 зображень.

Усі зображення (які мали різну роздільну здатність) спочатку були змінені до 48x192x20 використовуючи 3D-інтерполяцію.

Тривимірні МРТ зображення були представлені як осьові поперечні зрізи зображені на рис. 3.1.




Рис. 3.1. Забарвлений фрагмент з одного з оригінальних зображень МРТ

Після зменшення розмірів пікселі зображення перетворюються на постійні значення, придатні для використання з програмним забезпеченням машинного навчання на наступному кроці. Далі були об'єднані діагностичні групи. Отримані набори даних також містять метадані у формі діагностичної групи (тобто мітка для кожного навчального екземпляра).

Далі було використано інший метод для зменшення розмірності зображень за допомогою гістограм. У цій версії кожне зображення було стандартизоване шляхом масштабування кожного значення вокселів до діапазону $(0,1)$. Потім було обчислено гістограму на тривимірному зображенні.

Останню версію набору даних було зменшено шляхом простого зменшення всіх МРТ-зображень до $69 \times 95 \times 79$ за допомогою тривимірного зменшення масштабу. Фінальна варіація включала 1615 зображень загалом для навчання згорткової мережі.

3.3.3. Об'єднання діагностичних груп

Набори даних МРТ-зображень були позначені відповідним класом (0 – Хворий, 1 – Легкі когнітивні порушення, 2 – Здоровий). Після цього набір даних було перетасовано. Потім набір даних розділено на навчальний та тестовий набір із співвідношенням 70/30 (70% для тренувань і 30% для тестування).

Усі зменшені набори даних були розділені на чотири варіанти об'єднаних класів (для полегшення бінарних класифікацій):

1. Нормальний / Легке когнітивне порушення / Хворий
2. Нормальний / Інший
3. Легке когнітивне порушення / Інший
4. Хворий / Інший

3.3.4. Сегментація зображень

Сегментація — це процес розділення цифрового зображення на декілька сегментів. Сегменти якісно просегментованого зображення повинні бути однорідними за текстурою, межі виділених сегментів повинні бути чіткими, сусідні сегменти повинні відрізнятися за певними критеріями. Загалом, усі методи сегментації можна поділити на такі категорії: методи, що базуються на кластеризації, методи з використанням гістограм, методи

розростання областей, методи розрізу графа, водорозподілу, методи, що базуються на виділенні країв, багатомасштабна сегментація.

Для досягнення результатів я використав різні типи сегментації зображень, а саме виділення країв та порогова сегментація:

Виділення країв. Межі та краї областей сильно пов'язані, оскільки часто існує сильний перепад яскравості на кордонах областей. Тому методи виділення країв використовуються як основа для іншого методу сегментації.

Порогова сегментація. Один із основних і найпростіших способів - це побудова сегментації за допомогою порогу. Поріг - це ознака (властивість), що допомагає розділити шуканий сигнал на класи. Операція порогового поділу полягає в зіставленні значення яскравості кожного пікселя зображення з заданим значенням порога. Сегментація зображень виконувалась за допомогою методів наявних в бібліотеках, які описані далі.

3.3.5. Програмне забезпечення та використання бібліотек

Оскільки експерименти проводились з деякими новішими методами, мені довелося провести оцінку деяких найпопулярніших сучасних інструментів нейронної мережі. Оскільки увага приділялася простоті експериментів та підтримці відносно останніх хитрощів та прийомів, я обрав мову Python та бібліотеки Pylearn, Scikit-learn для розроблення програмного забезпечення.

Для розроблення програмного забезпечення існували декілька важливих факторів при виборі програмних засобів. В першу чергу бібліотеки з якими потрібно було легко експериментувати, оскільки експерименти значною мірою полягали у порівнянні різних варіацій набору даних. Також обробка зображень та навчання повинно бути порівняно ефективно та швидко виконані, оскільки буде проведено багато експериментів. Нарешті, повинні бути підтримані сучасні методи, такі як регуляризація, аналіз основних компонентів та інші оскільки дають змогу

підвищити якість обробки зображень та продуктивність роботи програми за певних обставин.

`Pylearn` – це передова бібліотека машинного навчання для Python, розроблена в Монреальському університеті, побудована з урахуванням досліджень. Особлива увага приділяється глибокому навчанню. Бібліотека орієнтована на просте налаштування для експертних користувачів (тобто дослідників машинного навчання) – подібні бібліотеки, які забезпечують хороші показники роботи, не вимагаючи знань про основні алгоритми від користувачів. Один із способів сказати, що бібліотека цінує простоту експериментів над простотою використання. Хоча `Pylearn` передбачає певну технічну складність з боку користувачів, бібліотека також зосереджується на повторному використанні, а отримана модульність дає можливість поєднувати та адаптувати декілька повторно використовуваних компонентів для формування робочих моделей та лише для того, щоб дізнатися про частини бібліотеки, якими хочеться користуватися. `Pylearn` використовує інтерфейс `YAML`, який дозволяє користувачам швидко налаштовувати та виконувати експерименти визначення їх моделей у майже деклараційному стилі, використовуючи заздалегідь визначені компоненти як будівельні блоки та вказуючи гіпер-параметри. Крім того, експерименти також можуть бути визначені через сценарій Python.

`Scikit-learn` – це одна бібліотека машинного навчання для Python. Спираючись на широко використовувані пакети, такі як `numpy` (N-мірний масив) та `scipy` (наукові обчислення), містить різноманітні алгоритми класифікації, регресії та кластеризації, що надають методи машинного навчання для контрольованих та неконтрольованих проблем. Пакет "фокусується на тому, щоб наблизити машинне навчання до неспеціалістів", і таким чином є більш доступним, ніж деякі альтернативи.

`Pylearn` значною мірою створений та підтримується його користувачами (студентами `LISAlab` та іншими співробітниками), і оскільки він зосереджений на дослідженні, функції додаються в міру необхідності,

тобто користувачам, ймовірно, доведеться тиражувати опубліковані результати або виконувати варіанти на старих експериментах наборах даних. Pylearn постачається з підтримкою та готовим до використання стандартизованим набором даних орієнтирів (таких як MNIST та CIFAR-10) та без підконтрольним навчанням поза коробкою. На відміну від Pylearn, який зосереджується здебільшого на нейронних мережах, Scikit-learn має широкий спектр наявних машинних методів навчання, включаючи підтримуючі векторні машини, логістичну регресію, найближчих сусідів та випадкові ліси, що охоплюють такі завдання, як класифікація, регресія, кластеризація, зменшення розмірності, вибір моделі та попередня обробка моделі. Веб-сайт бібліотек містить вичерпну документацію. Він включає обмежену підтримку нейронних мереж, але не дуже практично використовувати для глибокого навчання. Тому я вирішив використовувати ці дві бібліотеки для розробки програмного забезпечення

Був розроблений інтерфейс, який дає змогу завантаження зображення мозку та розпізнавання хвороби Альцгеймера.

Веб-інтерфейс рис 3.1 був розроблений за допомогою бібліотеки Django.

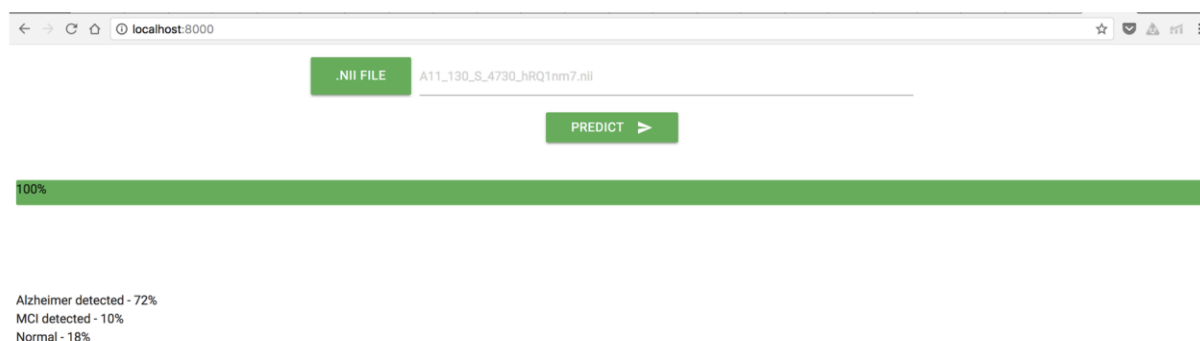


Рис 3.2 Інтерфейс для завантаження набору даних

Через веб інтерфейс можна завантажити МРТ-зображення та отримати результат показаний на екрані.

Під час роботи було створено кілька додаткових інструментів:

1. Перетворювач наборів даних – це окремий додаток інтерфейсу командного рядка, який здійснює одночасне перетворення набору даних відповідно до запропонованого способу .
2. Клас набору даних – це клас python для використання з бібліотекою Pylearn, який завантажує перетворений набір даних ADNI і автоматично розбиває його на підгрупи навчальних тестів і перевірок.
3. Web-interface через який можна завантажити набір даних.
4. Для прискорення обчислень використовувались хмарні обчислення Amazon Web Services.

Наступні інструменти були обрані, оскільки, як відомо, вони мали гарну реалізацію відповідних алгоритмів. Усі етапи проекту можна знайти у спеціальному загальнодоступному сховищі github.

Програмне забезпечення було реалізоване за допомогою бібліотеки PyLearn та Scikit-learn. Всі експерименти, які описані далі проводились з використанням хмарних обчислень Amazon Web Services для швидкодії навчання нейронної мережі.

3.5. Висновки

У задачах класифікації або розпізнавання величезною перевагою нейронних мереж над спеціалізованими алгоритмами постає їх здатність до навчання, тому у розділі розглянуті основні ідеї та методи реалізації цього складного процесу. Щоб покращити та пришвидшити процес навчання, а також уникнути такої події, як перенавчання, мереж звертаються до математичних засобів, таких як алгоритм зворотнього поширення помилки або процедур нормалізації.

Було досліджено декілька сучасних програмних бібліотек нейронної мережі, зокрема тих, що підтримують глибоке навчання. Оцінити якість мереж допомагають такі показники, як точність та втрата (обраховується функцією втрат), побудувавши графік яких, чи подавши у вигляді таблиць, можна провести аналітику напрацьованих результатів.

Більшість бібліотек дуже схожі. Багато нових опцій серед програмного забезпечення або частково реалізовані або мають прив'язку до мови програмування. Також поширеними (особливо серед нових бібліотек) є відносно ліберальні ліцензії з відкритим кодом та наявність дуже активних спільнот розробників, що сприяють подальшій дискусії та розробці.

Pylearn цінує простоту експериментів над простотою використання. Він має мінімальну документацію, але це дуже легко експериментує з потужними моделями та може використовувати прискорення GPU або хмарні обчислення.

Scikit-learn має широке значення, коли мова йде про техніку машинного навчання, і є також дуже доступний для використання з іншими бібліотеками. Всі обчислення проводились з використанням Amazon Web Services.

4. ПРОВЕДЕННЯ ЕКСПЕРИМЕНТІВ ТА ПОРІВНЯННЯ ОТРИМАНИХ РЕЗУЛЬТАТІВ

4.1. Проведення експериментів

В магістерській дисертації точність класифікації використовується як метрика продуктивності. Було оцінено точність, специфічність та чутливість порівнюючи їх з результатами минулих робіт.

У цьому розділі представлені результати навчання нейронної мережі. Всі експерименти проводилися за допомогою розділення набору даних 70% / 30% (тренування / тестування). Це було зроблено для того, щоб забезпечити достатню кількість даних для достовірності варіації з меншою кількістю екземплярів.

Таким чином, процедуру роботи можна описати наступним чином:

- Зміна розмірності зображень до найнижчої роздільної здатності в наборі даних
- Об'єднання класів (тобто діагностичних груп)
- Сегментація зображень
- Навчання нейронної мережі
- Проведення експериментів

Після цього було проведено ряд експериментів (тобто з усіма комбінаціями зменшення розмірів, сегментації зображень та об'єднаних класів) з використанням згорткових нейронних мереж, навчання нейронної

мережі проводилось приблизно пару годин. Зазвичай вимірювання ефективності в галузі машинного навчання включають: p та f значення, специфічність та чутливість, довірчі інтервали, значимість, характеристику помилок (наприклад, зміщення та дисперсії), криву ROC та відсотки помилок на стандартизованих наборах даних [4], але я обійшовся лише трьома показниками.

Було проведено навчання базової моделі з установкою таких параметрів:

- Алгоритм зворотного поширення помилки.
- Темп навчання -10^{-4} .
- Розмір серії – 64.
- Кількість епох – 1000.

Мережа була багатошаровим перцептроном, використовуючи \tanh як функцію активації, з критеріями припинення: максимум 10000 епох; відсутність зниження швидкості помилкової класифікації в 25 епохах; коефіцієнт неправильної класифікації нижче 0,01. Мережа була запущена з трьох кратною стратифікованою перехресною валідацією.

4.2. Сегментація зображень

Під час проведення експериментів були використані різні типи сегментації зображень для досягнення більш точних показників мережі. 1615 зображень були використані для навчання згорткової нейронної мережі. У наборі даних було три типи зображень (Хворий(585), Легкі когнітивні порушення(460) та Здоровий(570)). Після цього 1292 зображення були використані для тренування моделі та 323 для тестування. У рамках першого піддослідю було проведено шість оціночних процесів. Фрагменти результатів зображені на рис. 4.1.




Рис. 4.1. Шість типів сегментації зображень

У першій оцінці використовували повне зображення, не виявляючи жодного краю. Також друге оцінювання було виконано із застосуванням повних зображень після виявлення країв. Третє і четверте оцінювання проводили зі збільшенням області з та без виявлення ребер. П'яте оцінювання проводилося з обмеженим збільшенням області без виявлення ребер. Нарешті, останню оцінку проводили з обмеженим збільшенням області із виявленням ребер. Після порівняння шести процесів оцінювання в першому під експерименті, для другого під експерименту було обрано найкращий метод сегментації.. Згідно з результатами, отриманими з першого піддослідю, очевидно, що оцінка 3(збільшення області без виявлення ребер) забезпечує найкращу оцінку серед інших типів сегментацій, які показані в табл. 4.1.

Таблица 4.1

Оцінка типів сегментації

Тип сегментації	Чутливість %	Специфічність %
1	86	93
2	92	96
3	96	98
4	93	96
5	89	95
6	92	96

Тому, використовуючи цей метод сегментації, у другому під експерименті було впровадженно згорткову нейронну мережу яка складається з 1615 зображень з різними варіаціями діагностичних груп. З цих зображень 1292 зображення були вибрані випадковим чином для навчання та 323 для тестування моделі згорткових нейронних мереж. Наведені результати показані в таблиці 4.2 та порівнянні з результатами методу опорних векторів.

4.3. Аналіз отриманих результатів

В таблиці 4.2 було винесено найкращі оцінки навчання мережі на наборах даних. Результати показані в таблиці продемонстрували, що показник точності значно вищий з використанням згорткових нейроонних мереж приблизно на 10 відсотків.

Таблиця 4.2

Результати проведених досліджень

Набір даних	Метод	Чутливість %	Специфічність %	Точність %
1615	SVM	84,2	87,8	85,0
1615	CNN	96,1	98,3	97,0

В основному таких задовільних результатів було досягнуто шляхом зменшення розмірності зображень, сегментації зображень, об'єднанні діагностичних груп, поєднання функції активації ReLU, техніки Dropout, збільшеної кількості навчальних даних для виявлення маркерів та навчання мережі використовуючі хмарні обчислення.

Також застосування нормалізації зображень значно збільшило час тренування мережі: чим менший розмір серії використовується, тим більшим стає час навчання для кожної епохи . Висока точність за нижчих розмірів серії була емпірично підтверджена. Однак розмір серії під час проведених експериментів можливо був занадто низьким, тому і отримано значну затримку у часі навчання мережі.

Більшу кількість класів легше класифікувати, якщо кожен новий клас подається з більшою кількістю даних. Це можна пояснити тим, що відмінність об'єкта від фону має аналогічні властивості навіть для різних класів.

Навчання та тестування нейронної мережі на особистому комп'ютері з використанням простого GPU проходило повільніше, якщо порівнювати з результатами часу в хмарних обчисленнях. пов'язано це з тим, що модифікована архітектура базової моделі отримала більше фільтрів вхідного шару та збільшений розмір підвибірки максимуму, що призвело до незначного збільшення параметрів в мережі.

4.4. Висновки

Відповідно до припущень, висловлених на початку обмежена область для виявлення ребер дозволяє досягти найкращу точність. В процесі дослідження було оцінено метод класифікації зображень, для яких було отримано результати, які показані в таблиці. При застосуванні згорткових нейронних мереж було досягнуто найкращу точність виявлення ознак деменції мозку.

Аналіз результатів експериментів дозволив виявити, що *SVM* не дозволяє з прийнятною точністю виявляти симптоми легкого та помірного випадків хвороби та не працює в класичних класифікаціях. Тому *SVM* не можна використовувати для ранньої діагностики хвороби. Проте точність класифікації можна вдосконалити за допомогою методів глибокого навчання. Тому було прийнято рішення використати згорткові нейронні мережі.

Другий експеримент складався з двох тестів. У першому тесті оцінювалась ефективність різних методів сегментації зображень та об'єднання різних діагностичних груп. Як показав аналіз результатів, повне зображення не забезпечує правильної класифікації. Причина цього полягає в тому, що повне зображення є надто складним. Далі область особливостей була зменшена для отримання більш детальних ознак зображення мозку.

Однак при цьому різко знижується продуктивність виявлення, оскільки алгоритм видаляє всі зображення білої та сірої речовини із зображення мозку.

5. СТАРТАП

5.1. Опис проблеми

Сучасне суспільство все більше звертається до комп'ютеризованої методики діагностування та лікування різноманітних хвороб. А новітні наукові розробки та автоматизація процесів дозволяє робити ці процеси надзвичайно ефективним, швидкими та максимально корисними.

Автоматизована діагностика – це процес визначення фізичного стану пацієнта і його оцінки, вираженої у прийнятій медичній термінології, що ґрунтується на всебічному систематичному дослідженні організму пацієнта за допомогою технічних засобів, що допомагають провести процес за короткий термін і з більшою точністю. Системи такого типу є базовими для створення на їх основі систем підтримки прийняття рішень.

Хвороба Альцгеймера – це нейродегенеративне захворювання, що веде до смерті нейронів головного мозку людини. Загибель нейронів призводить до тяжких розладів пам'яті, інтелекту та когнітивних функцій. Дані зміни ведуть за собою проблеми в емоційно-особистісній сфері і поведінці та є найбільш поширеною формою слабоумства. Більшість людей, які страждають хворобою, відчувають деяку помірну втрату пам'яті, яка суттєво впливає на їх повсякденне життя, а також інші симптоми (дратівливість, часту зміну настрою та ін.).

Раннє виявлення хвороби Альцгеймера є важливим для запобігання вживанню профілактичних заходів. Сучасні методики виявлення хвороби покладаються на тестування когнітивних порушень, яке, на жаль, не дає точних діагнозів, поки хвороба не прогресує. Хвороба Альцгеймера вважається однією з гострих захворювань, які призводять до смерті людини, особливо у людей старше 60 років.

Найбільш поширеними інженерними методами діагностики хвороби є магнітно-резонансна томографія та позитронно-емісійна томографія(однофотонна емісійна комп'ютерна томографія). Перший метод дозволяє виявити структурні зміни у тканинах головного мозку, в той час як другий є функціональним методом і дозволяє оцінити порушення метаболізму.

MPT (магнітно-резонансна томографія) є одним з джерел засобів виявлення захворювань мозку, але використання MPT в класифікації Альцгеймера вважається складним процесом відповідно до дисперсії та складності тканини мозку.

Багато систем автоматизованої діагностики зараз широко поширені у медицині. Тому було запропоновано автоматизовану і надійну комп'ютерну систему діагностики та класифікації захворювань головного мозку для виявлення хвороби Альцгеймера.

5.2. Зацікавлені сторони

Однією з проблем сучасної охорони здоров'я є низький рівень оснащеності засобами діагностики медичних установ населених пунктів і низька кваліфікація медичного персоналу. Це часто обумовлює несвоєчасне виявлення захворювань, лікування яких на більш пізній стадії є малоефективним. Розробка нових діагностуючих пристроїв для томографії дозволить оснастити різні медичні установи і виявляти ранні стадії захворювання у широкого кола населення, що сприятиме значному підвищенню ефективності лікування.

Тому, в першу чергу, зацікавленими сторонами є компанії, що виробляють дані пристрої. На світовому ринку компаній, що виробляють МРТ-сканери не так вже й багато, тому конкуренція досить висока. Світовими виробниками-лідерами є компанії: Philips, Hitachi, Siemens, GE. Тільки такі великі компанії можуть дозволити собі розробку такого складного обладнання, вартість якого як правило становить десятки мільйонів гривень.

Дані компанії постійно проводять дослідження по вдосконаленню своїх пристроїв, а особливо щодо вдосконалення якості зображення томографів. Але вдосконалення зображення саме по собі не позбавляє від проблеми встановлення невірної або не точного діагнозу

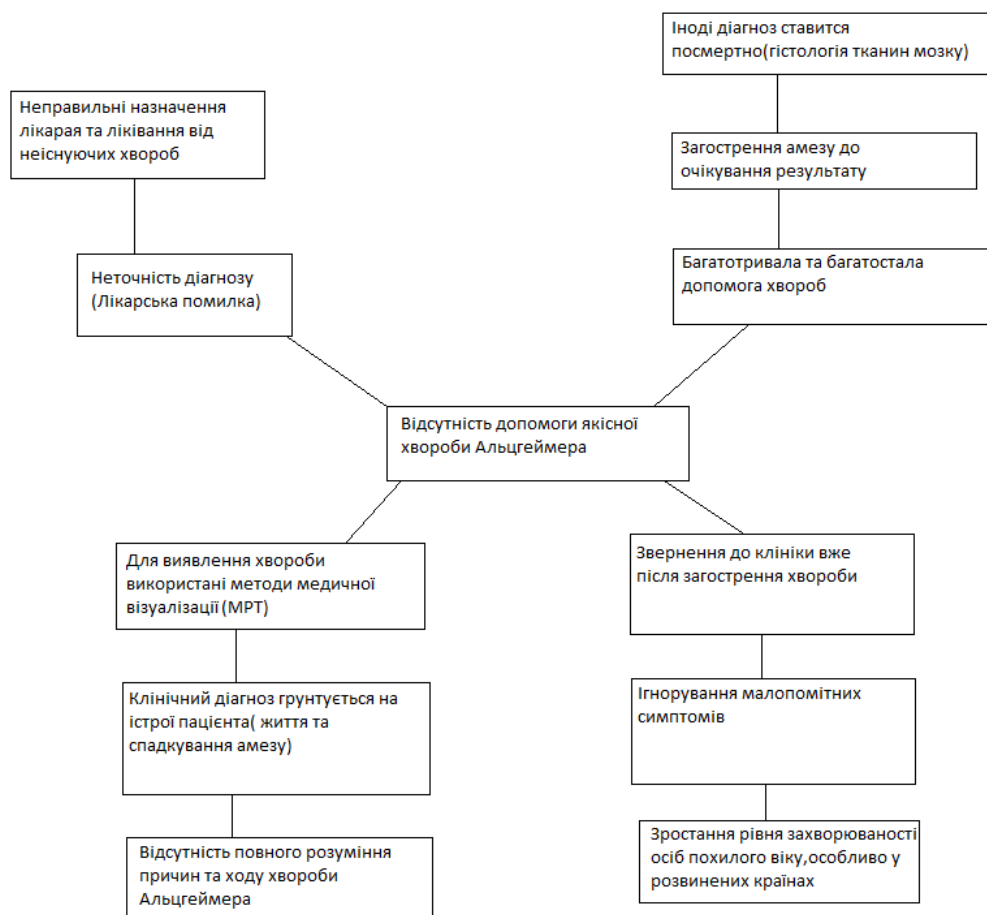


Рис. 5.2. Дерево проблем

. Програмне забезпечення по автоматичному розпізнаванню захворювань дозволить позбутися даної проблеми.

Програму пропонується встановлювати при виробництві самого томографу. Так само, як сьогодні ми купуємо ноутбук з встановленою ОС Windows, клініки зможуть купувати МРТ-пристрій з вже встановленою програмою автоматичного розпізнавання медичних зображень. Програма не тільки виведе функціональність пристрою на новий рівень, а і дозволить значно збільшити його кінцеву вартість.

Наступною категорією зацікавлених осіб є самі клініки, що закуповують дороговартісні МРТ-сканери. Сам по собі сканер дозволяє лише отримати чітке зображення мозку, але не діагностує хворобу чи певний його стан. Цією справою займається лікар. Саме тут починається дія “людського фактору”. Програма дозволяє частково позбутися даного фактору, тобто самостійно встановлює стадію хвороби, виводячи всі дані на екран. Завдання лікаря лише поставити кінцевий діагноз та назначити пацієнту програму лікування, якщо він цього потребує.

Клініка також є зацікавленою у автоматизації даного процесу, оскільки це дає змогу поставити точний діагноз і в даному випадку репутація закладу залежить тільки від кваліфікації лікарів. Виведення на екран зображення з відміченими частинами захворювання має звести нанівець лікарську помилку і забезпечує правильний діагноз.

Ще однією зацікавленою категорією є держава. Розвинуті держави щорічно витрачають мільйони доларів на розвиток нейронауки, створюючи дослідницькі лабораторії і навіть влаштовуючи конкурси з призовими фондами серед науковців і дослідних команд по застосуванню методів з використанням нейронних мереж у медицині. Держава зацікавлена у тому щоб її громадяни були здоровими. Для цього більшість МОЗів намагаються забезпечувати державні клініки усіма необхідними приладами для раннього виявлення важко виліковних хвороб.

І, накінець, зацікавленими сторонами є самі громадяни, які переймаються своїм здоров'ям, можуть мати схильність до спадкових захворювань. Їх здоров'я напряду залежить від діагнозу лікаря, що ставить його на основі отриманого зображення. Знаючи про існування даної технології, пацієнти будуть згодні витратити більше коштів на обстеження з даною програмою аби уникнути лікарської помилки.

Сегментація споживачів за технікою 5W (What? Who? Why? When? Where?). Продукт програма попереднього розпізнавання медичних зображень з використанням нейронних мереж:

Таблиця 5.2

Показники зацікавленості сторін

Зацікавлена сторона	Інтерес зацікавленої сторони	Ступінь впливу зацікавленої сторони	Стратегії приваблення зацікавлених сторін
Компанії-виробники МРТ-сканерів	Значне вдосконалення вже існуючого продукту	Високий	Презентації для компаній-виробників, медичні виставки, ярмарки, стартап-презентації, конкурси для розробників, персональні пропозиції для компаній, державні програми.
Клініки	Унікальність у проведенні діагностики, підвищення вартості діагностики, репутація закладу	Середній	Медичні виставки та презентації, персональні пропозиції для клінік, державні програми

Держава	Збереження здоров'я громадян	Високий	Подання пропозицій на державному рівні, отримання державних грантів, залучення державної підтримки
---------	------------------------------	---------	--

5.3. Комерційне рішення

Відповідно до вищезазначених проблем, можна описати кінцевий продукт, що має їх вирішувати. Даний програмний продукт буде реалізовувати описаний у попередній розділах автоматизований метод розпізнавання хвороби Альцгеймера на медичних зображеннях за допомогою нейронних мереж.

Даний метод дозволяє автоматично розпізнати на знімках, зроблених за допомогою МРТ-машин, уражені ділянки мозку пацієнта. А це, в свою чергу, дозволить мінімізувати людський фактор при встановленні діагнозу. Дана програма дозволить вивести діагностику хвороби Альцгеймера на новий рівень, відкриваючи можливості раннього діагностування хвороби. Програма може бути інтегрована та обробляти знімки з будь-якої МРТ машини, незалежно від її торгової марки.

Як вже було зазначено вище – основними клієнтами є компанії-виробники томографів, клініки, що мають дане обладнання або планують його закупити та держава, що спонсорує заходи з охорони здоров'я.

5.4. Конкурентні переваги рішення

Нові методи досліджень дозволяють спостерігати за активністю мозку людини в режимі реального часу, за здатністю нервової системи навчатися і виправляти помилки. По аналогії з роботою мозку вчені намагаються

побудувати інформаційно-математичні моделі з тим, щоб створити штучний інтелект для вирішення різного роду практичних завдань, в тому числі в області медицини.

Цифрова нейронаука знаходиться зараз на початковій стадії свого розвитку. Сучасні лабораторії тільки починають шукати методи ранньої діагностики важковиліковних або взагалі невиліковних хвороб, тому, наразі реалізації схожої програми не існує.

Зараз існують окремі наукові дослідження, наприклад алгоритм ранньої діагностики раку, що передбачає ступінь агресивності пухлини, тобто знаходить коефіцієнт швидкості ділення клітин, але реальні розробки у діагностиці хвороби Альцгеймера поки що відсутні.

Тобто, дана програма може зайняти абсолютно порожню нішу програм-надбудов для МРТ машин, що автоматично розпізнає знімки з томографа на наявність хвороби Альцгеймера.

5.5. Сегмент ринку споживання

Як вже зазначалося вище, клієнтами є компанії-виробники томографів (B2B), клініки (B2B) та держава (B2G).Даних клієнтів пропонується розподілити за такою ознакою, як рівень розвитку медицини у країні.

Компанії-виробники здебільшого локалізовані у високорозвинених країнах, де медицина знаходиться на досить високому рівні – США, Японія, Німеччина, Нідерланди. Відсоток клінік, що закуповують дане обладнання у цих країнах також високий.

За даними MarketLine розмір світового ринку медичного обладнання та пов'язаних з цих послуг (GlobalHealthCareEquipment & Supplies) склав в 2016 року 361,7768 млрд.долл. Ринок характеризувався досить високими темпами зростання (CAGR) -в середньому, 5,1% в рік в період 2009-2013, причому за прогнозами експертів, ці темпи повинні були зберегтися в 2013-2018 роках. Динаміка розвитку загальносвітового ринку медичного обладнання та окремих регіонів позначена на рис. 5.5.




Рис. 5.5. Темпи розвитку медичного обладнання та пов'язаних з ним послуг

З наведених малюнків видно, що найбільш великим за розміром ринком є ринок медичного обладнання американського регіону, темпи розвитку цього сегмента близькі до загальносвітових, наступним за величиною ринком є ринок європейського регіону (найнижчі темпи розвитку), а найшвидше (але аж ніяк не найбільшим) ринок азіатсько-тихоокеанського регіону.

Найбільшими ринками медичного обладнання в Європі вважаються ринки Німеччини, Франції, Великобританії, Італії, Іспанії. Дані країни не тільки експортують але і активно імпортують медичне обладнання.

Зі сторони участі держави у охороні здоров'я її громадян лідирують наступні країни:

- Швеція – 97% покриття затрат на охорону здоров'я;
- Швейцарія, – де кожен громадянин забезпечений медичним полісом;
- Південна Корея;
- Австралія – з універсальною медичною системою, федеральний уряд компенсує приблизно 75% медичних рахунків громадян, в той час як 25% фінансується приватним медичним страхуванням;
- Італія – всі операції в Італії безкоштовні як в громадських, так і в приватних лікарнях. Невідкладна медична допомога абсолютно

безкоштовна для всіх жителів, навіть нелегально проживають на території країни;

- Іспанія – за ліки, що відпускаються за рецептом, платять через спеціальну систему доплати, де жителі зобов'язані платити за невелику частину їх ліків;
- Ізраїль – система регулюється державою і є однією з найбільш технологічно розвинених в світі, з сучасним обладнанням і добре навченими лікарями і медсестрами;
- Японія – найбільш інноваційна країна у напрямку медичного обладнання.
- Японія забезпечує універсальне медичне страхування, яке субсидує значну частину медичних витрат людини;
- Сингапур
- Гонконг – найкраща охорона здоров'я в світі, частково завдяки його добре розвиненій медичній системі. Рівень тривалості життя тут один з найвищих.

Отже, якщо виробників МР-томографів на сьогоднішній день лише декілька у світі, то з країн найбільш перспективними для співпраці є ті, в яких рівень розвитку медицини є дійсно високим і тому клініки на території даних країн, а також держава, мають у своєму розпорядженні ресурси, достатні для інвестицій у дороговартісні програми з використанням нейромереж.

Епідеміологія хвороби Альцгеймера також може бути ознакою для сегментації ринку та орієнтацією на ті сегменти, де проблема стоїть найбільш гостро. Найбільш розповсюдженою дана хвороба є серед жителів Північної Америки – 6,4% жителів віком 60+. На другому місці стоїть Західна Європа – 5,4%, Латинська Америка – 4,6%, розвинуті країни і західна частина Тихого океану (Австралія, Нова Зеландія, Сингапур) - 4,3%. Східна Європа, за статистикою ВОЗ, має 3,9%.

5.6 Доходи та витрати

Сумарний дохід вираховується як сума доходу від продажу патентної ліцензії на використання програмного забезпечення. Патентне ліцензування – це надання власником патенту дозвіл на використання технічної документації або запатентованих винаходів. У більшості випадків така ліцензія є комерційною. За ліцензійним договором власник ОІВ (ліцензіар) в якості винагороди бажає отримати паушальний платіж та роялті:

- Паушальний платіж – одноразовий платіж, який становить фіксовану суму і не залежить від обсягів виробництва (продажу) продукції (товарів, робіт, послуг) з використанням ОІВ;
- Роялті – ліцензійний платіж у вигляді сум, які виплачуються періодично, залежно від обсягів виробництва або реалізації продукції (товарів, робіт, послуг) з використанням ОІВ;
- Комбінований платіж (кост-пласт) – ліцензійний платіж, що включає роялті та паушальний платіж.

Розмір роялті встановлюється сторонами ліцензійного договору за результатами оцінки вартості об'єктів прав інтелектуальної власності, здійсненої Суб'єктом оціночної діяльності згідно ЗУ, або законодавством іншої країни, яке буде регулювати дані взаємовідносини.

Комерційне ПЗ, що буде передбачено ліцензією — програмне забезпечення, створене комерційною організацією з метою отримання прибутку від його використання іншими, наприклад, шляхом продажу копій. Найважливішою особливістю комерційний програмних продуктів є підтримка компанії, прямо зацікавленої у поширенні свого програмного продукту. Багато організацій надають виключно платну підтримку своїх продуктів, такий підхід, як правило, використовують організації надають відкриті вихідні коди.

Витрати на саму реалізацію проекту можна побачити у табл. 5.6.

Місячні витрати реалізації проекту

Найменування витрат	1 місяць, тис. \$	2 місяць, тис. \$	3 місяць, тис. \$	4 місяць, тис. \$	5 місяць, тис. \$	6 місяць, тис. \$
Загальні витрати	30	20	20	20	20	20
ЗП		25	25	25	25	25
Витрати	30	45	45	45	45	45
Заплановані прибутки						
Результат без оподаткування	30	45	45	45	45	45
	7 місяць, тис. \$	8 місяць, тис. \$	9 місяць, тис. \$	10 місяць, тис. \$	11 місяць, тис. \$	12 місяць, тис. \$
Загальні витрати	20	20	20	20	20	20
ЗП	30	30	30	30	30	30
Витрати	50	50	50	50	50	50
Заплановані прибутки	104	104	104	104	104	104
Результат без оподаткування	54	54	54	54	54	54

Передбачається, що технічна підтримка продукту буде надаватися на безоплатній основі, але, як показує практика, її сума закладається у роялті.

Для продуктів, що розповсюджуються на комерційній основі діють зазвичай безкоштовні служби підтримки, покликані збільшити рівень довіри у клієнтів і потенційних покупців. Даний вид ПЗ, на відміну від вільного ПЗ або пропрієтарного, не надає право на вільну модифікацію коду, а також його поширення і отримання з нього прибутку.

Технічна підтримка включає комплекс організаційних і технічних заходів, спрямованих на забезпечення функціонування програмного продукту, включаючи його встановлення, налаштування, оновлення та відновлення. В табл. 5.7 підсумовуються дані з попередньої таблиці та отримаємо загальний результат

Таблиці 5.7

Загальний результат витрат проекту

	Загальні витрати	ЗП	Витрати	Заплановані прибутки	Результат без оподаткування
Загальний результат, тис. \$	250	305	555	624	69

5.7. Унікальна ціннісна пропозиція

Унікальна ціннісна пропозиція - це визначна характеристика продукту. Вона використовується для диференціації споживачем даного продукту серед інших, аналогічних.

За допомогою дерева проблем у розділі 5.1. виділено низку проблем, а у зацікавлених сторонах – було визначено очікування відповідних сторін від продукту.

Виробники МРТ томографів бажають вдосконалити вже існуючий продукт, а медичні установи – знизити ризик лікарської помилки і тим самим, підвищити свою репутацію та кваліфікацію, держава зацікавлена у ефективній боротьбі з невиліковною хворобою, що з кожним роком набирає

обертів, а пацієнти хочуть знати точний діагноз. Запропоноване рішення, у вигляді програмного забезпечення, дозволяє частково задовольнити всі з наведених вище вимог зацікавлених сторін та вирішити наведені проблеми.

Отже, основною унікальною ціннісною пропозицією є розроблений метод автоматизованого визначення деструктивних змін у мозку, що інформують про наявність хвороби Альцгеймера, на медичних зображеннях.

Основною перевагою є те, що алгоритм розпізнає відразу декілька ділянок мозку, враховуючи найменші деструктивні зміни, що дозволяє поставити діагноз на ранній стадії захворювання.

5.8. Бізнес модель

Гарантія того, що продукт відповідає потребам ринку, є лише однією зі складових успіху. Інший ключовий фактор - відповідь на питання, як проєкт має приносити дохід? І тут вступає в гру бізнес-модель.

Як уже було вказано, надходження прибутків буде відбуватися через регулярні ліцензійні платежі - роялті. Тобто бізнес-модель, що буде взята за основу - ліцензування.

Все більше компаній вважають за краще отримувати прибуток від своїх ідей і інтелектуальних активів, не вкладаючи кошти в комерціалізацію. Так сформувалася модель ліцензування. Бізнес-модель продажу і використання ПЗ, при якій постачальник розробляє ПЗ і самостійно керує ним, забезпечуючи підтримку програми та її оновлення і надаючи замовнику доступ до програмного забезпечення.

Узагальнимо, все написане вище у формі одного з інструментів бізнес-управління для опису бізнес-моделей - lean canvas. Споживачі: виробники МР-томографів, клініки та держава. Проблема: відсутність автоматизованих рішень виявлення хвороби Альцгеймера; високий вплив людського фактору на остаточний діагноз і як наслідок - високий %

лікарської помилки; виявлення хвороби вже на досить пізніх стадіях; відсутність єдиного високоточного методу виявлення хвороби.

Рішення: програмне забезпечення, що з дуже високою точністю визначає деструктивні зміни у мозку на медичних знімках. автоматично виділяючи уражені та видозмінені ділянки мозку.

Унікальна ціннісна пропозиція: програмне забезпечення, що за допомогою нейронних мереж аналізує медичні знімки головного мозку на предмет наявності деструктивних змін, що свідчать про те, що пацієнт має хворобу Альцгеймера.

Потоки доходів: доходи від продажу ліцензій; доходи від запуску вдосконалених версій (у перспективі).

Структура витрат: утримання персоналу для надання технічної підтримки (виплати заробітних плат, соціальних виплат); утримання робочих місць для персоналу (оплата за оренду офісу та комунальні послуги); податкові витрати; оплата послуг юриста, бухгалтера, прибиральниці.

Також в канву бізнес-моделі включаються структурні блоки: прихована перевага (перевага, яку неможливо скопіювати або купити), ключові метрики (основні показники, що вимірюються) та канали (шляхи до користувачів). Канали: через прямі продажі, презентації, виставки, державні гранти. Ключові метрики: кількість проданих ліцензій.

Прихована перевага: врахування навіть найменших деструктивних змін при автоматизованому визначенні хвороби. Бізнес-модель наведена у зведеному вигляді у таблиці 5.8 - канвас модель:

Отже, зважаючи на дані можна зробити висновок, що запропонований проект, який реалізує описаний у дипломі метод визначення хвороби Альцгеймера, має перспективи у своїй подальшій реалізації.

Таблиця 5.8

Бізнес модель продукту

Проблема	Рішення	Унікальна ціннісна пропозиція	Прихована перевага	Споживачі
відсутність автоматизованих рішень виявлення хвороби Альцгеймера; високий вплив людського фактору на остаточний діагноз і як наслідок - високий % лікарської помилки; виявлення хвороби вже на досить пізніх стадіях; відсутність єдиного високоточного методу виявлення хвороби.	програмне забезпечення, що з дуже високою точністю визначає деструктивні зміни у мозку на медичних знімках. автоматично виділяючи уражені та видозмінені ділянки мозку.	програмне забезпечення, що за допомогою нейронних мереж аналізує медичні знімки головного мозку на предмет наявності деструктивних змін, які свідчать про те, що пацієнт має хворобу Альцгеймера.	врахування навіть найменших деструктивних змін при автоматизованому визначенні хвороби.	виробники МРТ-томографів клініки держава
	Ключові метрики		Канали	
	кількість проданих ліцензій.		прямі продажі; презентації; виставки; державні гранти.	
Структура витрат			Потоки доходів	

утримання персоналу для надання технічної	доходи від продажу ліцензій;
---	------------------------------

Звичайно, проведений аналіз не враховує всіх ризиків та факторів, таких як специфіка оподаткування у країні ведення бізнесу, проте навіть наявних досліджень достатньо, щоб прогнозувати комерційний успіх продукту та його окупність.

5.9. Висновки

У п'ятому розділі було проведено аналіз поточної ситуації у сфері визначення хвороби Альцгеймера, виявлено наявні проблеми та підсумовано їх у відповідному дереві проблем. Наряду з проблемами було виділено основні зацікавлені сторони у вирішенні існуючих недоліків та ступінь впливу даних сторін на вирішення проблем. Як наслідок було запропоновано комерційне рішення з конкурентними перевагами, що задовольняє інтереси зацікавлених осіб, та виділено унікальну ціннісну пропозицію запропонованого продукту.

Було проведено аналіз майбутніх клієнтів, досліджено сегменти ринку споживання. Це дозволило спрогнозувати потенційні доходи та витрати на реалізацію продукту. У результаті була описана бізнес-модель, що обґрунтовує доцільність реалізації даного продукту та прогнозує його потенційну окупність та прибутковість в подальшому.

ВИСНОВКИ

Ця магістерська дисертація дає відповідь на два дослідницьких питання. У чому полягає доцільність методів, що застосовувались у попередніх дослідженнях для діагностики хвороби Альцгеймера, таких як метод опорних векторів, у завданні ранньої діагностики та наскільки можливо реалізувати методи глибокого навчання, такі як згорткові нейронні мережі, для попереднього виявлення симптомів Альцгеймера.

На першому етапі магістерської роботи для аналізу магнітно резонансної томографії-зображень мозку було застосовано метод опорних векторів. Загалом, має меншу похибку узагальнення, ніж інші класифікатори, тому зазвичай використовується для вирішення задач класифікації шаблонів. Під час дослідження було застосовано класифікатор для діагностики здорових груп контролю та пацієнтів з хворобою, використовуючи зображення мозку. Для цього використано базу даних МРТ-зображень з нейровізуалізацією мозку хвороби Альцгеймера, оскільки там є явні біомаркери порушень в м'яких тканинах і органах. Для експериментів випадковим чином вибрано підмножину сканування з початкового набору даних. У першому дослідженні досягнуто точність 85,0%, чутливість 84,2% та специфічність 87,8%.

На другому етапі роботи було застосовано метод аналізу зображень на основі згорткових нейронних мереж, який у загальному випадку отримує кращі результати порівняно з будь-якими іншими методами класифікації зображень. Архітектура складається з двох згорткових шарів, одного

об'єднаного шару та повністю пов'язаного шару. Для вибору найкращого методу сегментації та оцінки надійності моделі було виконано два тести. Попередньо оброблені зображення додатково оброблялися з метою досягнення найкращого результату. Зображення були поділені на відповідні класи. Після цього набір даних був перетасований та розділений на навчальний набір і тестовий набір із співвідношенням 80% для тренувань і 20% для тестування.

У експерименті були використані різні типи сегментації зображень, щоб більш точно досягти результату. Для навчання моделі були використані 1615 зображень, зокрема, 1292 зображення були використані для тренування моделі та 323 для тестування. У рамках першого експерименту було проведено шість оціночних процесів, а саме сегментації зображень. Відповідно до припущень, висловлених на початку дослідження, обмежена область з виявленням ребер дозволяє досягти найкращу точність. При застосуванні згорткових нейронних мереж було досягнуто найкращі результати виявлення ознак деменції мозку, а саме точність 95,0%, чутливість 96,1% та специфічність 98,3% .

Майбутні дослідження будуть зосереджені на покращенні продуктивності моделі. Найвища точність може бути досягнута шляхом збільшення кількості даних, що використовуються для підготовки моделі. Тому доцільно виконати експеримент для перевірки моделі, збільшивши кількість зображень, які використовуються для тренування.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Мітчелл, Т. Машинне навчання / Том Мітчелл – Квітень 2008. 240 – 269 ст.
2. Marilyn, A. The diagnosis of mild cognitive impairment due to Alzheimer's disease: recommendations from the National Institute on Aging-Alzheimer's Association workgroups on diagnostic guidelines for Alzheimer's disease / Marilyn Albert. – May 2011. 270 – 279 p.
3. Berg, L. Neuropathological indexes of Alzheimer's disease in demented and nondemented persons aged 80 years and older / Li Berg. – Apr. 1993. 349 – 358 p.
4. Dickson, W. Identification of normal and pathological aging in prospectively studied nondemented elderly humans/ Wan Dickson. – Feb 1992. 179 – 189 p.
5. Kloppel, S. Automatic classification of MR scans in Alzheimer's disease/ Sammant Kloppel. – May 2008. 681 – 689 p.
6. Farina, N. Vitamin E for Alzheimer's dementia and mild cognitive impairment/ Nina Farina. – Nov 2012. 74 – 79 p.
7. Martin Prince, A. The Global Impact of Dementia An AnAlysIs of prevAlence/ Albert Martin Prince. – March 2015. 89 – 95 p.
8. Saman, S., Danielle D. Alzheimer's Disease Classification via Deep Convolutional Neural Networks using MRI and fMRI, Cold Spring Harbor Laboratory/ Saman Sarraf. – May 2018. 134 – 140 p.
9. Fayao, L. Learning Deep Convolutional Features for MRI Based Alzheimer's Disease Classification / Fayao Liu. – Apr 2018. 220 – 230 p.

10. Rajkumar. A, CAD Approach for MRI Brain Alzheimer Recognition and Classification/ Ahmar Rajkumar. – Jan 2016, India. 240 – 245 p.
11. Ron Brookmeyer, Forecasting the global burden of Alzheimer's disease. Alzheimer's & dementia: the journal of the Alzheimer's Association/ Ron Brookmeyer. – July 2007, India. 186 –191 p.
12. Dickson D. W., Identification of normal and pathological aging in prospectively studied nondemented elderly humans/Dickson Doney Willi – Feb. 1992, USA. 179–189 p.
13. Andrew G. Howard, Some Improvements on Deep Convolutional Neural Network Based Image Classification/Andrew Georg Howard – Dec. 18, 2013.
14. Jonathan H. Morra, Comparison of AdaBoost and support vector machines for detecting Alzheimer's disease through automated hippocampal segmentation/Jonathan H. Morra – May. 2016, 30–43 p.
15. Adrien Payan and Giovanni Montana, Predicting Alzheimer's disease: a neuroimaging study with 3D convolutional neural networks/Adrien Payan and Giovanni Montana – Apr. 2017, 145–150 p.
16. Pascal Vincent, Extracting and composing robust features with denoising autoencoders/Pascal Vincent – Sep. 2018, 1096–1103 p.
17. Matthew D. Zeiler and Rob Fergus, Visualizing and Understanding Convolutional Networks/Matthew D. Zeiler and Rob Fergus – Sep. 2017, 153–201 p
18. Stefan Klöppel, Automatic classification of MR scans in Alzheimer's disease/Stefan Klöppel – Sep. 2016, 681–689 p.
19. Згорткова нейронна мережа [Електронний ресурс].. Режим доступу: http://uk.wikipedia.org/wiki/Згорткова_нейронна_мережа.

ДОДАТКИ

ДОДАТОК 1

Лістинг коду програми

GenerationData.py

```
class DataGenerator(object):
    'Generates data for Keras'
    def __init__(self, dim_x = 32, dim_y = 32, dim_z = 32, batch_size = 32,
shuffle = True):
        'Initialization'
        self.dim_x = dim_x
        self.dim_y = dim_y
        self.dim_z = dim_z
        self.batch_size = batch_size
        self.shuffle = shuffle

    def generate(self, labels, lists):
        'Generates batches of samples'
        # Infinite loop
        while 1:
            # Generate order of exploration of dataset
            indexes = self.__get_exploration_order(lists)

            # Generate batches
            imax = int(len(indexes)/self.batch_size)
            for i in range(imax):
                # Find list of IDs
                lists_temp = [lists[k] for k in
indexes[i*self.batch_size:(i+1)*self.batch_size]]

                # Generate data
                X, y = self.__data_generation(labels, lists_temp)

                yield X, y

    def __get_exploration_order(self, lists):
        'Generates order of exploration'
        # Find exploration order
        indexes = np.arange(len(lists))
        if self.shuffle == True:
            np.random.shuffle(indexes)

        return indexes

    def __data_generation(self, labels, list_arrs_temp):
        'Generates data of batch_size samples' # X : (n_samples, v_size,
v_size, v_size, n_channels)
        # Initialization
```

```

        X = np.empty((self.batch_size, self.dim_x, self.dim_y,
self.dim_z),dtype=int)
        y = np.empty((self.batch_size), dtype = int)

# Generate data
for i, arr in enumerate(list_arrs_temp):
    # Store volume
    if arr.shape != (6720,64,64):
        arr = np.transpose(arr, [2, 1, 0])
    #print arr.shape
    X[i] = arr

# Store class
y[i] = labels[i]
return X, sparsify(y)

def sparsify(y):
    'Returns labels in binary NumPy array'
    n_classes = 3 # Enter number of classes
    return np.array([[1 if y[i] == j else 0 for j in range(n_classes)]
                      for i in range(y.shape[0])])

```

Main.py

```

from keras.models import Sequential
from keras.layers import Dense, Dropout, Flatten
from keras.layers import Conv2D, MaxPooling2D,
GlobalAveragePooling2D,TimeDistributed, LSTM, Conv3D
from keras.applications import VGG16
from keras import backend as K
from keras import regularizers
from sklearn.preprocessing import OneHotEncoder
import os
import numpy as np
import nibabel as nib # to read nii files
import shutil # for file operations
import glob # use to make file list from diectory
import matplotlib.pyplot as plt
import cv2 # opencv library
import matplotlib.image as mpimg
import random
from sklearn.model_selection import train_test_split
import traceback
import sys
import keras
from gen import DataGenerator

```

```

classes = ['Alzheimer','MCI', 'Normal']
# Declaring the home variables that will be used throughout the
script.

home_files_dir = '/home/ubuntu/Select_original_fmri/'
#output_dir='/home/ubuntu/final_src/DeepNeuralnets--
Alzheimer/videoclassification/'

train_list=[]
test_list=[]
file_list=[]

for class_ in classes:
    print ('working on ' + class_ + '...')

    for root, dir ,files in os.walk(os.path.join('output_array',
class_)):
        length=len(files)
        print("root: ",root)
        if class_ == 'Alzheimer':
            for file_ in files:
                npy = np.load(root+'/'+file_)
                if npy.shape == (64, 64, 6720):
                    file_list.append((npy,0))
            #image data division
            test_list=file_list[:int(length*0.2)]
            train_list=file_list[len(test_list):]

        elif class_ == 'MCI':
            len2=len(file_list)
            for file_ in files[:25]:
                npy = np.load(root+'/'+file_)
                if npy.shape == (64, 64, 6720):
                    file_list.append((npy,1))
            #image data diision
            test_list +=file_list[len2:int(len2+length*0.2)]
            train_list += file_list[int(len2+length*0.2):]

# for Normal Class

else:
    len3=len(file_list)
    for file_ in files:

```

```

        npy = np.load(root+'/'+file_)
        if npy.shape == (64, 64, 6720):
            file_list.append((npy,2))
#image data diision
test_list += file_list[len3:int(len3+length*0.2)]
train_list += file_list[int(len3+length*0.2):]

#print ("length of train list: ",len(train_list))
#print("length of train labels:",len(train_labels))
#print("length of test list:",len(test_list))
#print("length of test labels:",len(test_labels))
np.random.shuffle(train_list)
np.random.shuffle(test_list)
X_train,Y_train=zip(*train_list)
X_test,Y_test=zip(*test_list)

#X_train=np.array(X_train,dtype=np.uint8)
#Y_train=np.array(Y_train,dtype=np.uint8)
#X_test=np.array(X_test,dtype=np.uint8)
#print X_test.shape
#Y_test=np.array(Y_test,dtype=np.uint8)
X_test = np.transpose(X_test, [0, 3, 2, 1])
#print X_train.shape
#X_train = np.transpose(X_train, [0, 3, 2, 1])

#for i in X_train:

#    print("X train shape: ",i.shape)
#print("Y label shape: ",Y_train.shape)
#print("X test shape: ",X_test.shape)
#print("Y test label: ",Y_test.shape)
#print('done...')

# Parameters
params = {'dim_x': 6720,
          'dim_y': 64,
          'dim_z': 64,
          'batch_size': 1,
          'shuffle': True}

training_generator = DataGenerator(**params).generate(Y_train,
X_train)
validation_generator = DataGenerator(**params).generate(Y_test,
X_test)

batch_size = 1

```

```

input_shape = [6720, 64,64]
#Y_train= np_utils.to_categorical(Y_train, num_classes=3)
#Y_test= np_utils.to_categorical(Y_test, num_classes=3)
#np.random.shuffle(data)
#print(X_train.shape)
#print(Y_train.shape)
#print(X_test.shape)
#print(Y_test.shape)
#del(train_list)
#del(test_list)
model = Sequential()
model.add(Conv2D(
    32, (3,3), activation='relu', input_shape=input_shape))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Conv2D(64, (3,3), activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Conv2D(128, (3,3), activation='relu'))
model.add(Conv2D(128, (3,3), activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Conv2D(256, (2,2), activation='relu'))
model.add(Conv2D(256, (2,2), activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))

model.add(Flatten())
model.add(Dense(32))
model.add(Dropout(0.5))
model.add(Dense(3, activation='softmax'))
model.summary()

model.compile(loss=keras.losses.categorical_crossentropy,
              optimizer=keras.optimizers.Adadelta(),
              metrics=['accuracy'])

print Y_train
print Y_test
# model.fit(X_train, Y_train, batch_size=batch_size,
# epochs=100, verbose=1, validation_data=(X_test, Y_test))
# Train model on dataset
model.fit_generator(generator = training_generator,
                   steps_per_epoch = len(X_train)//batch_size,
                   epochs = 2,
                   validation_data = validation_generator,
                   validation_steps = len(X_test)//batch_size)
Y_test= np_utils.to_categorical(Y_test, num_classes=3)
print X_test[0].shape
for i in range(len(X_train)-2):
    print i,i+1
    print model.predict_classes(nX_train[i:i+1])

```

```

#score = model.evaluate(X_test, Y_test, verbose=0)
json_string = model.to_json()
with open("arch.json","w") as f:
    f.write(json_string)
model.save_weights("weights.h5")
#print('Test loss:', score[0])
#print('Test accuracy:', score[1])

```

Test.py

```

import os

import numpy as np
import nibabel as nib # to read nii files
import shutil # for file operations
import glob
from keras.models import Sequential
import keras

# Declaring the home variables that will be used throughout the script.

home_files_dir = '/home/ubuntu/Select_original_fmri/'
#output_dir='/home/ubuntu/final_src/DeepNeuralnets--
Alzheimer/videoclassification/'

loaded_model = Sequential()
# load json and create model
json_file = open('arch.json', 'r')
loaded_model_json = json_file.read()
json_file.close()
loaded_model = keras.models.model_from_json(loaded_model_json)
# load weights into new model
loaded_model.load_weights("weights.h5")
nii_file=[]

#removing existing "output_array" (old data) folder from the directory
'/home/ubuntu/Select_original_fmri/images
# iterating /home/ubuntu/Select_original_fmri/niifiles/class_
classes=("Alzheimer", "MCI" , "Normal")
for class_ in classes:
    print ('working on ' + class_ + '...')

    for root, dir ,files in os.walk(os.path.join(home_files_dir+"niifiles/" ,
class_)):

        count = 0
        for file_ in files:

```

```

        #print 'working on ' + file_ + '...'
        #try:
            # extracting data from nii files
            x = nib.load(os.path.join(home_files_dir+"niifiles/" , class_) +
'/' + file_).get_data()
            print("x_shape",x.shape)
            x_arr=np.array(x)
            #print ("x_arr shape : ",x_arr.shape)
            #converting X_arr into 3_D array.....
            x_3d =
x_arr.reshape(x_arr.shape[0],x_arr.shape[1],x_arr.shape[2]*x_arr.shape[3])
            out=loaded_model.predict_classes(x_3d)
            print out
            #np.save('output_array' + '/' + class_ +
'/' +str(file_)+str(count),x_3d)
            count+=1
            #print("3d array shape : ",x_3d.shape)
            break
        #except:
            print("in last except block")
            print file_
            break

```